



Guide de l'utilisateur

AWS Glue



AWS Glue: Guide de l'utilisateur

Copyright © 2025 Amazon Web Services, Inc. and/or its affiliates. All rights reserved.

Les marques commerciales et la présentation commerciale d'Amazon ne peuvent pas être utilisées en relation avec un produit ou un service extérieur à Amazon, d'une manière susceptible d'entraîner une confusion chez les clients, ou d'une manière qui dénigre ou discrédite Amazon. Toutes les autres marques commerciales qui ne sont pas la propriété d'Amazon appartiennent à leurs propriétaires respectifs, qui peuvent ou non être affiliés ou connectés à Amazon, ou sponsorisés par Amazon.

Table of Contents

Qu'est-ce que c'est AWS Glue ?	1
AWS Glue fonctionnalités	2
En savoir plus sur les innovations dans AWS Glue	4
Démarrage avec AWS Glue	4
Accès AWS Glue	4
Services connexes	5
Comment ça marche	6
Travaux ETL sans serveur exécutés en isolation	7
Concepts	8
AWS Glue terminologie	11
Composants	14
AWS Glue console	15
AWS Glue Data Catalog	15
AWS Glue chenilles et classificateurs	16
AWS Glue Opérations ETL	16
Streaming d'ETL en AWS Glue	17
Le système AWS Glue d'emplois	17
Composants ETL visuels	18
AWS Glue pour Spark et AWS Glue pour Ray	24
Qu'est-ce que c'est AWS Glue pour Ray ?	25
Conversion de schémas semi-structurés en schémas relationnels	26
AWS Types de colle	28
AWS Types de catalogues de données Glue	28
Types dans les scripts AWS Glue with Spark	28
AWS Types de Glue Crawler	29
Premiers pas	30
Vue d'ensemble de l'utilisation AWS Glue	30
Configuration des autorisations IAM	32
Étapes suivantes	37
Configuration pour AWS Glue Studio	37
Commencer à utiliser les blocs-notes dans AWS Glue Studio	51
Configuration des profils d'utilisation	53
Gestion des profils d'utilisation	55
Profils d'utilisation et emplois	67

Démarrage avec le plugin AWS Glue Data Catalog	68
Présentation	68
Étape 1 : Créer une base de données	68
Étape 2. Créer une table	70
Étapes suivantes	71
Configuration de l'accès réseau aux magasins de données	75
Configuration d'un VPC pour se connecter à PyPI pour AWS Glue	76
Configuration du DNS de votre VPC	78
Configuration du chiffrement	79
Configuration du réseau pour le développement	83
Configuration de votre réseau pour un point de terminaison de développement	83
Configuration d'Amazon EC2 pour un serveur d'ordinateurs portables	86
Découverte et catalogage des données	88
Remplissage du catalogue de données	91
À l'aide d'un AWS Glue crawler	92
Définition manuelle des métadonnées	184
Intégration à d'autres AWS services	205
Paramètres du catalogue de données	206
Remplissage et gestion des tables transactionnelles	209
Création de tables Iceberg	210
Optimisation des tables Iceberg	213
Optimisation des performances des requêtes pour les tables Iceberg	246
Gestion du catalogue de données	248
Mise à jour du schéma et ajout de nouvelles partitions	249
Optimisation des performances des requêtes à l'aide des statistiques des colonnes	257
Chiffrement de votre catalogue de données	283
Sécurisation de votre catalogue de données à l'aide de Lake Formation	283
Utilisation des AWS Glue Data Catalog vues	284
Accès au catalogue de données	288
Connexion au catalogue de données à l'aide du point de terminaison AWS Glue Iceberg REST	290
Connexion au catalogue de données à l'aide du point de terminaison de l'extension AWS Glue Iceberg REST	293
AWS Glue REST APIs pour Apache Iceberg	294
Connexion au catalogue de données depuis une application Spark autonome	314
Cartographie des données entre Amazon Redshift et Apache Iceberg	315

Considérations et limites relatives à l'utilisation du catalogue REST d' AWS Glue Iceberg	
APIs	317
Bonnes pratiques en matière de catalogue de données	317
Surveillance des métriques d'utilisation du catalogue de données dans Amazon CloudWatch ..	318
Vue d'ensemble des métriques du catalogue de données	319
Ajouter des métriques à votre CloudWatch tableau de bord	319
.....	320
AWS Glue Registre de schémas	321
Schémas	322
Registres	324
Gestion des versions et compatibilité des schémas	325
Bibliothèques Serde en open source	331
Quotas du registre des schémas	331
Comment ça marche	332
Premiers pas	334
Intégration à AWS Glue Registre de schémas	357
Migration vers AWS Glue Registre de schémas	384
Connexion aux données	386
Présentation de l'utilisation des connecteurs et des connexions	386
Connexions unifiées	387
Types d'authentification pris en charge	391
Considérations	392
Connexions disponibles	392
Limites	395
AWS Glue propriétés de connexion	396
Propriétés de connexion requises	396
Propriétés de connexion JDBC	397
Propriétés de connexion MongoDB et MongoDB Atlas	403
Propriétés de connexion Salesforce	404
Connexion Snowflake	404
Connexion Vertica	405
Connexion SAP HANA	406
Connexion Azure SQL	407
Connexion Teradata Vantage	408
OpenSearch Connexion au service	409
Connexion Azure Cosmos	410

Propriétés de connexion SSL	410
Propriétés de connexion Kafka pour l'authentification	413
BigQuery Connexion à Google	415
Connexion Vertica	405
Stockage des informations de connexion dans AWS Secrets Manager	415
Ajouter une AWS Glue connexion	416
Connexion à Adobe Analytics	418
Connexion à Adobe Marketo Engage	427
Connexion à Amazon Redshift	437
Connexion à Asana	442
Connexion à Azure Cosmos DB	452
Connexion à Azure SQL	455
Connexion à Blackbaud Raiser's Edge NXT	458
Connexion à CircleCI	468
Connexion à Datadog	481
Connexion à Docusign Monitor	488
Connexion à Domo	496
Connexion à Dynatrace	505
Connexion aux publicités Facebook	511
Connexion à Facebook Page Insights	519
Connexion à Freshdesk	542
Connexion à Freshsales	552
Connexion à Google Ads	559
Connexion à Google Analytics 4	588
Connexion à Google BigQuery	600
Connexion à la console de recherche Google	605
Connexion à Google Sheets	615
Connexion à HubSpot	622
Connexion aux publicités Instagram	649
Connexion à Intercom	657
Connexion à Jira Cloud	678
Connexion à Kustomer	705
Connexion à LinkedIn	733
Connexion à Mailchimp	741
Connexion à Microsoft Teams	752
Connexion à Mixpanel	763

Connexion au lundi	779
Connexion à MongoDB	788
Connexion à Oracle NetSuite	792
Connexion au OpenSearch service	803
Connexion à Okta	806
Connexion à PayPal	815
Connexion à Pendo	822
Connexion à Pipedrive	831
Connexion à Productboard	840
Connexion à QuickBooks	849
Connexion à Salesforce	857
Connexion à Salesforce Marketing Cloud	869
Connexion à Salesforce Commerce Cloud	895
Connexion à Salesforce Marketing Cloud Account Engagement	905
Connexion à SAP HANA	918
Connexion à SAP OData	922
Connexion à SendGrid	945
Connexion à ServiceNow	955
Connexion à Slack	966
Connexion à Smartsheet	978
Connexion à Snapchat Ads	990
Connexion à Snowflake	1000
Connexion à Stripe	1004
Connexion à Teradata	1054
Connexion à Twilio	1058
Connexion à Vertica	1078
Connexion à WooCommerce	1082
Connexion à Zendesk	1112
Connexion à Zoho CRM	1142
Connexion à Zoom Meetings	1153
Ajout d'une connexion JDBC à l'aide de vos propres pilotes JDBC	1164
Utilisation de connecteurs et de connexions personnalisés	1169
Création de connecteurs personnalisés	1171
Création de connexions pour les connecteurs	1176
Création de tâches avec des connecteurs personnalisés	1184
Gestion des connecteurs et des connexions	1192

Développement de connecteurs personnalisés	1195
Restrictions relatives à l'utilisation de connecteurs et de connexions dans AWS Glue	
Studio	1198
Tester un AWS Glue connexion	1198
Configuration des AWS appels pour qu'ils passent par votre VPC	1199
Connexion à un magasin de données JDBC dans un VPC	1200
Accès à des données de VPC par l'intermédiaire d'interfaces réseau Elastic	1200
Propriétés d'interface réseau Elastic	1202
Utilisation d'une connexion MongoDB ou MongoDB Atlas	1202
Analyse d'un magasin de données Amazon S3 à l'aide d'un point de terminaison d'un VPC ...	1203
Prérequis	1203
Création de la connexion à Amazon S3	1204
Test de la connexion à Amazon S3	1207
Création d'un crawler pour un magasin de données Amazon S3	1209
Création d'un crawler pour les tables du catalogue de données basées sur Amazon S3	1211
Exécution d'un crawler	1212
Résolution des problèmes	1212
Travailler avec des AWS Lake Formation données protégées	1213
Accès complet à la table	1213
Dépannage des problèmes de connexion	1214
Tutoriel : Utilisation du AWS Glue connecteur pour Elasticsearch	1215
Prérequis	1216
Étape 1 : (Facultatif) Créez un AWS secret pour les informations de votre OpenSearch cluster	1216
Étape 2 : S'abonner au connecteur	1217
Étape 3 : activer le connecteur AWS Glue Studio et créer une connexion	1218
Étape 4 : Configurer un rôle IAM pour votre tâche ETL	1219
Étape 5 : créer une tâche qui utilise la OpenSearch connexion	1219
Étape 6 : Exécuter la tâche	1221
Création AWS Glue d'emplois grâce à des sessions interactives	1222
Vue d'ensemble de AWS Glue sessions interactives	1222
Limites	1223
Démarrage avec AWS Glue sessions interactives	1223
Conditions préalables à la configuration locale des séances interactives	1223
Installation de Jupyter et de sessions AWS Glue interactives (noyaux Jupyter)	1223
Exécution de Jupyter	1224

Configuration des informations d'identification de séance et de région	1224
Mise à niveau à partir de l'aperçu des séances interactives	1226
Utilisation de sessions interactives avec SageMaker AI Studio	1226
Utilisation des séances interactives avec Microsoft Visual Studio Code	1227
Séances interactives avec IAM	1230
Configuration AWS Glue sessions interactives pour Jupyter et AWS Glue Studio blocs-notes	1238
Présentation de Jupyter magics	1238
Magics soutenu par AWS Glue sessions interactives pour Jupyter	1239
Désignation des séances	1257
Spécification d'un rôle IAM pour les séances interactives	1258
Configuration des séances avec des profils nommés	1259
Conversion d'un script ou d'un bloc-notes en AWS Glue tâche	1260
Utilisation des opérations de streaming dans AWS Glue sessions interactives	1260
Changement de type de séance de streaming	1260
Échantillonnage du flux d'entrée pour un développement interactif	1260
Exécution d'applications de streaming dans des séances interactives	1262
Développement et test locaux	1263
Développement à l'aide AWS de Glue Studio	1264
Développement à l'aide de sessions interactives	1264
Développer des AWS Glue emplois au niveau local avec Docker	1265
Points d'extrémité du développeur	1275
Migration des points de terminaison de développement vers des séances interactives	1277
Développement de scripts à l'aide de points de terminaison de développement	1279
Gestion des blocs-notes	1309
Création de tâches ETL visuelles avec AWS Glue Studio	1311
Se connecter à la console	1311
Prochaines étapes pour créer un emploi dans AWS Glue Studio	1312
Démarrage de tâches Visual ETL dans AWS Glue Studio	1312
Création d'un emploi dans AWS Glue Studio	1312
Fonctionnalités de l'éditeur de tâche	1314
Transformez les données avec AWS Glue transformations gérées	1322
Transformez les données grâce à des transformations visuelles personnalisées	1401
Utilisation des frameworks Data Lake avec AWS Glue Studio	1419
Connexion aux sources de données	1431
Configuration des nœuds de données cible	1441
Modification ou téléchargement d'un script de tâche	1447

Modification des noeuds parents d'un nœud dans le diagramme de tâche	1452
Suppression de noeuds du diagramme de tâches	1452
Ajout de paramètres source et cible au AWS Glue Nœud de catalogue de données	1457
Utilisation des systèmes de contrôle de version Git dans AWS Glue	1460
Création de code avec AWS Glue Studio blocs-notes	1468
Limites	1469
Présentation de l'utilisation des blocs-notes	1469
Création d'une tâche ETL à l'aide de blocs-notes dans AWS Glue Studio	1470
Composants de l'éditeur de bloc-notes	1471
Enregistrement de votre bloc-notes et de votre script de tâche	1472
Gestion des séances de bloc-notes	1473
Utilisation d'Amazon Q Developer avec AWS Glue Studio blocs-notes	1475
Surveillance des exécutions de tâches	1475
Accès au tableau de bord de surveillance de tâche	1475
Présentation du tableau de bord de surveillance de tâche	1475
Vue des exécutions de tâche	1476
Afficher les journaux d'exécution de la tâche	1481
Affichage des détails d'une exécution de tâche	1482
Afficher Amazon CloudWatch les statistiques relatives à l'exécution d'une tâche Spark	1485
Afficher Amazon CloudWatch les statistiques relatives à l'exécution d'une tâche Ray	1486
Détecter et traiter les données sensibles	1488
Choix du mode d'analyse des données	1489
Choix des entités PII à détecter	1490
Spécification du niveau de sensibilité de détection	1494
Choix de ce qu'il faut faire avec les données PII identifiées	1495
Ajout des remplacements précis des actions	1496
Gestion des tâches	1497
Démarrer une exécution de tâche	1497
Planifier des exécutions de tâche	1498
Gestion des planifications de tâche	1499
Arrêter les exécutions de tâche	1500
Voir vos tâches	1500
Afficher les informations sur les exécutions de tâche récentes	1501
Afficher le script de tâche	1502
Modifier les propriétés de tâche	1503
Sauvegarder la tâche	1506

Cloner une tâche	1509
Supprimer une tâche	1509
Travail avec les tâches	1511
AWS Glue versions	1512
AWS Glue versions	1512
AWS Glue politique de support des versions	1531
Migration AWS Glue des tâches Spark vers la AWS Glue version 5.0	1533
Migration AWS Glue des tâches Spark vers la AWS Glue version 4.0	1549
Analyse des mises à niveau avec l'IA	1564
Utilisation des tâches Spark	1582
Paramètres des tâches	1583
Spark et PySpark jobs	1593
Tâches ETL en streaming	1746
Record correspondant à FindMatches	1761
Migration de programmes	1799
Utilisation des tâches Ray	1807
Commencer avec AWS Glue For Ray	1807
Environnements d'exécution Ray pris en charge	1808
Comptabilité pour les travailleurs dans les tâches Ray	1809
Paramètres de tâche Ray	1810
Métriques des tâches Ray	1813
Configuration des propriétés des tâches du shell Python	1815
Limites	1815
Définition des propriétés pour les tâches shell Python	1816
Bibliothèques prises en charge pour les tâches shell Python	1818
Ajout de votre propre bibliothèque Python	1820
À utiliser AWS CloudFormation avec les jobs shell Python dans AWS Glue	1823
Migration du shell Python 3.6 vers le shell Python 3.9	1824
Migrer depuis les jobs shell AWS Glue Python	1824
Surveillance	1826
AWS balises	1827
Automatiser avec EventBridge	1833
Surveillance des ressources	1836
Journalisation en utilisant CloudTrail	1839
Statuts d'exécution de la tâche	1842
AWS Glue Streaming	1846

Cas d'utilisation pour le streaming	1846
Quels sont les avantages du AWS Glue streaming ?	1847
Quand utiliser le AWS Glue streaming ?	1848
Sources de données prises en charge	1849
Cibles de données prises en charge	1849
Tutoriel : Créez votre première charge de travail de streaming à l'aide de AWS Glue Studio ..	1850
Prérequis	1850
Utilisation des données de streaming à partir d'Amazon Kinesis	1850
Tutoriel : créez votre première charge de travail de streaming à l'aide des blocs-notes AWS	
Glue Studio	1861
Prérequis	1862
Utilisation des données de streaming à partir d'Amazon Kinesis	1862
Concepts du streaming	1869
Anatomie d'une tâche AWS Glue de streaming	1869
Connexions de streaming	1873
Connexions Kafka	1874
Connexions Kinesis	1880
AWS Glue mise à l'échelle automatique du streaming	1887
Activation d'Auto Scaling dans AWS Glue Studio	1888
Activer Auto Scaling avec la AWS CLI ou le SDK	1889
Comment ça marche	1890
Fenêtres de maintenance	1892
Configuration d'une fenêtre de maintenance	1892
Comportement des fenêtres de maintenance	1893
Surveillance des jobs	1894
Gestion des pertes de données	1896
Avancé AWS Glue concepts de streaming	1897
Considérations temporelles lors du traitement des flux	1897
Fenêtrage	1898
Gestion des données tardives et des filigranes	1904
Surveillance des tâches AWS Glue de streaming	1906
Visualisation des statistiques de AWS Glue streaming	1907
Utilisation des métriques AWS Glue de streaming	1908
Comment obtenir les meilleures performances	1913
Intégrations zéro ETL	1915
Fonctionnalités zéro ETL dans AWS Glue	1915

Prérequis	1916
Configuration des ressources sources	1917
Configuration des ressources cibles	1918
Création d'un entrepôt de données Amazon Redshift	1923
Configuration d'un VPC	1923
Configuration de l'intégration entre comptes	1927
Configuration d'une source	1928
Support pour les entités SAP spéciales	1928
Source Amazon DynamoDB	1928
Source Salesforce	1930
Source MCAE de Salesforce	1930
Configuration supplémentaire de Salesforce	1931
OData Source SAP	1931
ServiceNow source	1932
Source Zendesk	1932
Source de Zoho CRM	1932
Source de publicités Facebook	1934
Source de publicités Instagram	1934
Champs Salesforce non pris en charge	1935
Champs non pris en charge ServiceNow	1938
Configuration d'une cible	1943
SageMaker Lakehouse avec espace de rangement S3	1944
Cible des tables S3	1944
SageMaker Maison au bord du lac avec rangement Amazon Redshift	1948
Amazon Redshift cible de l'entrepôt de données	1949
Configuration de la cible d'intégration	1951
Dénidification des partitions et des schémas	1952
Comportement de dénidification et de partitionnement par défaut	1953
Désimbrication du schéma	1953
Partitionnement des données pour les intégrations sans ETL	1957
Limites	1967
Tâches courantes	1968
Création d'une intégration	1968
Modifier une intégration	1970
Supprimer une intégration	1970
En utilisant APIs	1970

Surveillance d'une intégration	1971
États d'intégration	1971
Affichage des journaux	1972
Affichage des métriques	1974
Notifications d'événements	1975
Limites	1976
AWS Glue Qualité des données	1986
Avantages et fonctionnalités clés	1986
Comment ça marche	1987
Qualité des données pour le AWS Glue Data Catalog	1987
Qualité des données pour les tâches AWS Glue ETL	1988
Comparaison des points d'entrée relatifs à la qualité des AWS Glue données	1988
Considérations	1990
Terminologie	1990
Limites	1992
Notes de publication AWS Glue relatives à la qualité des données	1992
Disponibilité générale : nouvelles fonctionnalités	1992
27 novembre 2023 (aperçu)	1993
12 mars 2024	1993
26 juin 2024	1993
7 août 2024	1993
22 novembre 2024	1994
6 déc. 2024	1994
30 juin 2025	1994
Détection d'anomalies dans AWS Glue Qualité des données	1994
Comment ça marche	1995
Détails de l'algorithme de détection des anomalies	2000
Autorisations IAM pour AWS Glue Data Quality	2001
Autorisations IAM	2002
Configuration IAM requise pour planifier les exécutions d'évaluation	2005
Exemple de politiques IAM	2006
Commencer à utiliser AWS Glue Data Quality pour le Data Catalog	2011
Prérequis	2012
Step-by-step exemple	2012
Génération de recommandations de règles	2012
Recommandations sur les règles de surveillance	2014

Modification des ensembles de règles recommandés	2015
Création d'un ensemble de règles	2016
Exécution d'un jeu de règles pour évaluer la qualité des données	2018
Affichage du score de qualité des données et des résultats	2019
Rubriques en relation	2020
Évaluation de la qualité des données avec AWS Glue Studio	2020
Avantages	2021
Évaluation de la qualité des données pour les tâches ETL dans AWS Glue Studio	2021
Générateur de règles de qualité des données	2032
Configuration de la détection des anomalies dans les jobs AWS Glue ETL	2037
Visualisation des scores de qualité des données et des anomalies	2040
Qualité des données pour les tâches ETL dans les blocs-notes AWS Glue Studio	2044
Prérequis	2045
Création d'une tâche ETL dans AWS Glue Studio	2045
Référence DQDL (Data Quality Definition Language)	2050
Syntaxe	2052
Référence du type de règle	2068
Utilisation APIs pour mesurer et gérer la qualité des données	2131
Prérequis	2131
Utilisation des recommandations relatives à AWS la qualité des données de Glue	2132
Travailler avec les ensembles de règles de qualité des données de AWS Glue	2135
Travailler avec AWS Glue Data Quality s'exécute	2137
Utilisation des résultats AWS de Glue Data Quality	2142
Configuration des alertes, des déploiements et de la planification	2148
Configuration des alertes et des notifications dans le cadre de EventBridge l'intégration	
Amazon	2149
Configurer des alertes et des notifications lors de l' CloudWatch intégration	2157
Interrogation des résultats de la qualité des données	2159
Déploiement des règles de qualité des données	2163
Planification de règles de qualité des données	2163
Le chiffrement des données est arrêté pour AWS Glue Data Quality	2163
AWS clés possédées	2163
Clés gérées par le client	2164
Création d'une clé gérée par le client	2167
Création d'une configuration de sécurité	2169
AWS Contexte de chiffrement de Glue Data Quality	2170

Surveillance de vos clés de chiffrement pour AWS Glue Data Quality	2171
En savoir plus	2175
Résolution des erreurs liées à la qualité des données de AWS Glue	2176
Erreur : module manquant	2177
Erreur : autorisations insuffisantes	2177
Erreur : les ensembles de règles ne sont pas uniques	2177
Erreur : tables contenant des caractères spéciaux	2177
Erreur : débordement avec un ensemble de règles volumineux	2177
Erreur : échec du statut de la règle	2178
AnalysisException: Impossible de vérifier l'existence de la base de données par défaut	2178
La clé de distribution fournie ne convient pas aux cadres de données fournies.	2179
java.lang. RuntimeException : Impossible de récupérer les données.	2179
ERREUR DE LANCEMENT : erreur lors du téléchargement depuis S3 pour le compartiment	2179
InvalidInputException (statut : 400) : DataQuality les règles ne peuvent pas être analysées	2180
Erreur : Eventbridge ne déclenche pas les tâches Glue DQ selon le calendrier que j'ai configuré.	2180
Erreurs CustomSQL	2181
Règles dynamiques	2181
Exception dans la classe utilisateur : org.apache.spark.sql. AnalysisException: org.apache.hadoop.hive.ql.metadata. HiveException	2184
UNCLASSIFIED_ERROR ; IllegalArgumentException : Erreur d'analyse : aucune règle ni analyseur fournis., aucune alternative viable en entrée	2184
Intégration des données Amazon Q dans AWS Glue	2185
Qu'est-ce qu'Amazon Q ?	2185
Intégration des données Amazon Q dans AWS Glue	2185
Utilisation de l'intégration des données Amazon Q	2186
Bonnes pratiques	2188
Amélioration du service	2189
Considérations	2189
Configuration de l'intégration des données Amazon Q	2189
Configuration des autorisations IAM	2189
Génération de code prise en charge	2192
Exemples d'interactions	2193
Interactions par chat avec Amazon Q	2193

AWS Glue Interactions avec Studio Notebook	2194
Utiliser la connaissance du contexte	2198
Exemple : interactions	2198
Limites	2202
Orchestration	2203
Démarrage des tâches et des crawlers à l'aide de déclencheurs	2203
AWS Glue déclencheurs	2203
Ajout de déclencheurs	2206
Activation et désactivation des déclencheurs	2210
Exécution d'activités ETL complexes à l'aide de plans et de flux de travail	2211
Présentation des flux de travail	2212
Création et développement d'un flux de travail manuellement	2216
Démarrer un flux de travail avec un EventBridge événement	2221
Afficher les EventBridge événements qui ont lancé un flux de travail	2229
Exécution et surveillance d'un flux de travail	2230
Arrêt d'une exécution de flux de travail	2232
Réparation et reprise de l'exécution d'un flux de travail	2233
Obtention et définition des propriétés d'exécution du flux de travail	2240
Interrogation des flux de travail à l'aide du AWS Glue API	2241
Restrictions du plan et du flux de travail	2245
Résolution des erreurs de plans	2247
Autorisations pour les personas et les rôles du plan	2252
Développement des plans	2256
Présentation des plans	2257
Développement des plans	2261
Enregistrement d'un plan	2286
Affichage des plans	2288
Mise à jour d'un plan	2290
Création d'un flux de travail à partir d'un plan	2293
Affichage des exécutions de plans	2295
AWS CloudFormation pour AWS Glue	2296
Exemple de base de données	2298
Exemple de base de données, de table, de partition	2299
Exemple de classificateur Grok	2303
Exemple de classifieur JSON	2304
Exemple de classifieur XLM	2305

Exemple d'un crawler Amazon S3	2306
Exemple de connexion	2309
Exemple d'un crawler JDBC	2310
Exemple de tâche pour Amazon S3 vers Amazon S3	2313
Exemple de tâche pour JDBC vers Amazon S3	2314
Exemple de déclencheur à la demande	2316
Exemple de déclencheur planifié	2317
Exemple de déclencheur conditionnel	2318
Exemple de transformation de machine learning	2320
Exemple d'ensemble de règles de qualité des données	2321
Exemple d'ensemble de règles de qualité des données avec planificateur EventBridge	2322
Exemple de point de terminaison de développement	2325
AWS Glue guide de programmation	2327
Fournir vos propres scripts personnalisés	2327
AWS Glue pour Spark	2328
Didacticiel : rédiger un script Spark	2329
ETL en PySpark	2342
ETL dans Scala	2581
Fonctionnalités et optimisations	2667
AWS Glue pour Ray	2943
Didacticiel : écrire un script Ray	2943
Utiliser Ray Core et Ray Data AWS Glue pour Ray	2950
Fournir des fichiers et des bibliothèques Python	2952
Connexion aux données	2957
Travailler avec AWS SDKs	2960
AWS Glue API	2962
Sécurité	2989
— les types de données —	2989
DataCatalogEncryptionSettings	2990
EncryptionAtRest	2990
ConnectionPasswordEncryption	2991
EncryptionConfiguration	2992
S3Encryption	2992
CloudWatchEncryption	2993
JobBookmarksEncryption	2993
SecurityConfiguration	2993

GluePolicy	2994
DataQualityEncryption	2994
— operations —	2995
GetDataCatalogEncryptionSettings (get_data_catalog_encryption_settings)	2995
PutDataCatalogEncryptionSettings (put_data_catalog_encryption_settings)	2996
PutResourcePolicy (put_resource_policy)	2997
GetResourcePolicy (get_resource_policy)	2998
DeleteResourcePolicy (supprimer_ressource_policy)	2999
CreateSecurityConfiguration (créer_configuration_sécurité)	3000
DeleteSecurityConfiguration (supprimer_configuration_sécurité)	3001
GetSecurityConfiguration (get_security_configuration)	3001
GetSecurityConfigurations (get_security_configurations)	3002
GetResourcePolicies (get_resource_policies)	3003
Objets du catalogue	3004
Catalogues	3004
Bases de données	3017
Tables	3027
Partitions	3075
Connexions	3101
Fonctions définies par l'utilisateur	3145
Importation d'un Athena catalogue	3152
Optimiseur de table	3154
— les types de données —	3154
TableOptimizer	3155
TableOptimizerConfiguration	3155
TableOptimizerVpcConfiguration	3156
CompactionConfiguration	3157
IcebergCompactionConfiguration	3157
TableOptimizerRun	3158
BatchGetTableOptimizerEntry	3159
BatchTableOptimizer	3160
BatchGetTableOptimizerError	3160
RetentionConfiguration	3161
IcebergRetentionConfiguration	3161
OrphanFileDeletionConfiguration	3162
IcebergOrphanFileDeletionConfiguration	3162

CompactionMetrics	3162
RetentionMetrics	3163
OrphanFileDeletionMetrics	3163
IcebergCompactionMetrics	3163
IcebergRetentionMetrics	3164
IcebergOrphanFileDeletionMetrics	3164
RunMetrics	3164
— operations —	3165
GetTableOptimizer (get_table_optimizer)	3165
BatchGetTableOptimizer (optimiseur de table par lots)	3167
ListTableOptimizerRuns (list_table_optimizer_runs)	3167
CreateTableOptimizer (create_table_optimizer)	3169
DeleteTableOptimizer (supprimer_table_optimiseur)	3170
UpdateTableOptimizer (optimiseur de table de mise à jour)	3171
crawlers et classifieurs	3172
Classifieurs	3173
Crawlers	3187
Statistiques de colonne	3215
Planificateur	3231
Génération automatique de scripts ETL	3234
— les types de données —	3234
CodeGenNode	3235
CodeGenNodeArg	3235
CodeGenEdge	3235
Emplacement	3236
CatalogEntry	3236
MappingEntry	3237
— operations —	3237
CreateScript (créer_script)	3238
GetDataflowGraph (get_dataflow_graph)	3238
GetMapping (get_mapping)	3239
GetPlan (get_plan)	3240
API Visual Job	3241
— les types de données —	3241
CodeGenConfigurationNode	3245
JDBCConectorOptions	3252

StreamingDataPreviewOptions	3254
AthenaConnectorSource	3254
JDBCConectorLa source	3255
SparkConnectorSource	3256
CatalogSource	3256
Ma SQLCatalog source	3257
Source de Postgrer SQLCatalog	3257
SQLCatalogSource d'Oracle	3258
Microsoft SQLServer CatalogSource	3258
CatalogKinesisSource	3258
DirectKinesisSource	3259
KinesisStreamingSourceOptions	3260
CatalogKafkaSource	3263
DirectKafkaSource	3263
KafkaStreamingSourceOptions	3264
RedshiftSource	3267
AmazonRedshiftSource	3267
AmazonRedshiftNodeData	3267
AmazonRedshiftAdvancedOption	3270
Option	3270
S3 CatalogSource	3271
S3 SourceAdditionalOptions	3271
S3 CsvSource	3272
Directement JDBCSource	3274
S3 DirectSourceAdditionalOptions	3275
S3 JsonSource	3275
S3 ParquetSource	3277
S3 DeltaSource	3279
S3 CatalogDeltaSource	3279
CatalogDeltaSource	3280
S3 HudiSource	3281
S3 CatalogHudiSource	3281
S3 ExcelSource	3282
CatalogHudiSource	3283
Source de dynamo DBCatalog	3284
RelationalCatalogSource	3284

JDBCConectorCible	3285
SparkConnectorTarget	3286
BasicCatalogTarget	3287
Ma SQLCatalog cible	3287
Cible Postgrer SQLCatalog	3288
SQLCatalogCible Oracle	3288
Microsoft SQLServer CatalogTarget	3289
RedshiftTarget	3289
AmazonRedshiftTarget	3290
UpsertRedshiftTargetOptions	3290
S3 CatalogTarget	3291
S3 GlueParquetTarget	3292
CatalogSchemaChangePolicy	3292
S3 DirectTarget	3293
S3 HudiCatalogTarget	3294
S3 HudiDirectTarget	3295
S3 DeltaCatalogTarget	3296
S3 DeltaDirectTarget	3297
S3 HyperDirectTarget	3298
S3 IcebergDirectTarget	3298
DirectSchemaChangePolicy	3299
ApplyMapping	3300
Mappage	3300
SelectFields	3302
DropFields	3302
RenameField	3302
Spigot	3303
Join	3304
JoinColumn	3304
SplitFields	3305
SelectFromCollection	3305
FillMissingValues	3305
Filtre	3306
FilterExpression	3307
FilterValue	3307
CustomCode	3307

SparkSQL	3308
SqlAlias	3309
DropNullFields	3309
NullCheckBoxList	3310
NullValueField	3310
Datatype	3311
Fusionner	3311
Union	3312
PIIDetection	3312
Regrouper	3313
DropDuplicates	3314
GovernedCatalogTarget	3314
GovernedCatalogSource	3315
AggregateOperation	3315
GlueSchema	3316
GlueStudioSchemaColumn	3316
GlueStudioColumn	3317
DynamicTransform	3317
TransformConfigParameter	3318
EvaluateDataQuality	3319
DQResultsPublishingOptions	3320
DQStopJobOnFailureOptions	3320
EvaluateDataQualityMultiFrame	3321
Recipe	3322
RecipeReference	3322
SnowflakeNodeData	3323
SnowflakeSource	3325
SnowflakeTarget	3325
ConnectorDataSource	3326
ConnectorDataTarget	3327
RecipeStep	3328
RecipeAction	3328
ConditionExpression	3329
Tâches	3329
Tâches	3329
Exécutions de tâches	3356

Déclencheurs	3376
Intégration APIs	3390
— les types de données —	3390
Integration	3391
IntegrationConfig	3392
IntegrationPartition	3393
IntegrationError	3394
IntegrationFilter	3394
InboundIntegration	3395
SourceProcessingProperties	3396
TargetProcessingProperties	3396
SourceTableConfig	3397
TargetTableConfig	3397
— operations —	3398
CreateIntegration (créer_intégration)	3398
ModifyIntegration (modifier_intégration)	3401
DescribeIntegrations (décrive_intégrations)	3404
DeleteIntegration (supprimer_intégration)	3405
DescribeInboundIntegrations (décrivez les intégrations entrantes)	3407
CreateIntegrationTableProperties (create_integration_table_properties)	3409
UpdateIntegrationTableProperties (update_integration_table_properties)	3410
GetIntegrationTableProperties (get_integration_table_properties)	3411
DeleteIntegrationTableProperties (supprimer_integration_table_properties)	3412
CreateIntegrationResourceProperty (create_integration_resource_property)	3413
UpdateIntegrationResourceProperty (update_integration_resource_property)	3415
GetIntegrationResourceProperty (get_integration_resource_property)	3416
UntagResource (untag_resource)	3417
ListTagsForResource (liste_tags_pour_ressource)	3417
— exceptions —	3418
ResourceNotFoundException	3418
InternalServerError	3418
IntegrationAlreadyExistsFault	3419
IntegrationConflictOperationFault	3419
IntegrationQuotaExceededFault	3419
KMSKeyNotAccessibleFault	3419
IntegrationNotFoundFault	3420

TargetResourceNotFound	3420
InvalidIntegrationStateFault	3420
Sessions interactives	3421
— les types de données —	3421
Session	3421
SessionCommand	3423
Instruction	3424
StatementOutput	3425
StatementOutputData	3425
ConnectionsList	3425
— operations —	3426
CreateSession (créer_session)	3426
StopSession (stop_session)	3430
DeleteSession (supprimer_session)	3431
GetSession (get_session)	3431
ListSessions (liste_sessions)	3432
RunStatement (run_statement)	3433
CancelStatement (annuler_déclaration)	3434
GetStatement (get_statement)	3435
ListStatements (liste_déclarations)	3436
DevEndpoints	3437
— les types de données —	3437
DevEndpoint	3437
DevEndpointCustomLibraries	3442
— operations —	3442
CreateDevEndpoint (create_dev_endpoint)	3443
UpdateDevEndpoint (update_dev_endpoint)	3448
DeleteDevEndpoint (supprimer_dev_endpoint)	3450
GetDevEndpoint (get_dev_endpoint)	3450
GetDevEndpoints (get_dev_endpoints)	3451
BatchGetDevEndpoints (batch_get_dev_endpoints)	3452
ListDevEndpoints (list_dev_endpoints)	3453
Registre de schémas	3454
— les types de données —	3454
RegistryId	3455
RegistryListItem	3455

MetadataInfo	3456
OtherMetadataValueListItem	3456
SchemaListItem	3457
SchemaVersionListItem	3458
MetadataKeyValuePair	3458
SchemaVersionErrorItem	3459
ErrorDetails	3459
SchemaVersionNumber	3459
Schemald	3460
— operations —	3460
CreateRegistry (créer_registre)	3461
CreateSchema (créer_schéma)	3462
GetSchema (get_schema)	3467
ListSchemaVersions (liste_schéma_versions)	3469
GetSchemaVersion (get_schema_version)	3470
GetSchemaVersionsDiff (get_schema_versions_diff)	3471
ListRegistries (list_registries)	3472
ListSchemas (liste_schémas)	3473
RegisterSchemaVersion (enregistre_schéma_version)	3474
UpdateSchema (schéma de mise à jour)	3476
CheckSchemaVersionValidity (check_schema_version_validity)	3477
UpdateRegistry (mise à jour du registre)	3478
GetSchemaByDefinition (get_schema_by_definition)	3479
GetRegistry (get_registry)	3480
PutSchemaVersionMetadata (put_schema_version_metadata)	3482
QuerySchemaVersionMetadata (query_schema_version_metadata)	3483
RemoveSchemaVersionMetadata (supprimer_schema_version_metadata)	3485
DeleteRegistry (supprimer_registre)	3486
DeleteSchema (supprimer_schéma)	3487
DeleteSchemaVersions (supprimer_les versions du schéma)	3488
Flux de travail	3490
— les types de données —	3490
JobNodeDetails	3490
CrawlerNodeDetails	3491
TriggerNodeDetails	3491
Crawl	3491

Nœud	3492
Edge	3493
Flux de travail	3493
WorkflowGraph	3494
WorkflowRun	3495
WorkflowRunStatistics	3496
StartingEventBatchCondition	3497
Plan	3497
BlueprintDetails	3499
LastActiveDefinition	3499
BlueprintRun	3500
— operations —	3501
CreateWorkflow (créer_flux de travail)	3502
UpdateWorkflow (flux de travail de mise à jour)	3503
DeleteWorkflow (supprimer_flux de travail)	3505
GetWorkflow (get_workflow)	3505
ListWorkflows (liste_flux de travail)	3506
BatchGetWorkflows (batch_get_workflows)	3507
GetWorkflowRun (get_workflow_run)	3508
GetWorkflowRuns (get_workflow_runs)	3508
GetWorkflowRunProperties (get_workflow_run_properties)	3509
PutWorkflowRunProperties (put_workflow_run_properties)	3510
CreateBlueprint (créer_un plan)	3512
UpdateBlueprint (mise à jour du plan)	3513
DeleteBlueprint (supprimer_le plan)	3514
ListBlueprints (liste_plans)	3514
BatchGetBlueprints (batch_get_blueprints)	3515
StartBlueprintRun (start_blueprint_run)	3516
GetBlueprintRun (get_blueprint_run)	3517
GetBlueprintRuns (get_blueprint_runs)	3518
StartWorkflowRun (start_workflow_run)	3519
StopWorkflowRun (stop_workflow_run)	3520
ResumeWorkflowRun (resume_workflow_run)	3520
Profils d'utilisation	3522
— les types de données —	3522
ProfileConfiguration	3522

ConfigurationObject	3522
UsageProfileDefinition	3523
— operations —	3524
CreateUsageProfile (créer un profil d'utilisation)	3524
GetUsageProfile (get_usage_profile)	3525
UpdateUsageProfile (mettre à jour le profil_d'utilisation)	3526
DeleteUsageProfile (supprimer_profil_d'utilisation)	3527
ListUsageProfiles (liste_profils_d'utilisation)	3527
Machine learning	3528
— les types de données —	3528
TransformParameters	3529
EvaluationMetrics	3530
MLTransform	3530
FindMatchesParameters	3533
FindMatchesMetrics	3535
ConfusionMatrix	3536
GlueTable	3537
TaskRun	3538
TransformFilterCriteria	3539
TransformSortCriteria	3540
TaskRunFilterCriteria	3540
TaskRunSortCriteria	3541
TaskRunProperties	3541
FindMatchesTaskRunProperties	3542
ImportLabelsTaskRunProperties	3542
ExportLabelsTaskRunProperties	3543
LabelingSetGenerationTaskRunProperties	3543
SchemaColumn	3543
TransformEncryption	3544
MLUserDataEncryption	3544
ColumnImportance	3545
— operations —	3545
Créer MLTransform (create_ml_transform)	3546
Mettre à jour MLTransform (update_ml_transform)	3549
Supprimer MLTransform (delete_ml_transform)	3552
Obtenir MLTransform (get_ml_transform)	3553

Obtenir MLTransforms (get_ml_transform)	3556
Liste MLTransforms (list_ml_transform)	3557
Démarrer MLEvaluation TaskRun (start_ml_evaluation_task_run)	3558
Démarrer MLLabeling SetGenerationTaskRun (start_ml_labeling_set_generation_task_run)	3559
MLTaskExécuter (get_ml_task_run)	3560
Obtenir des MLTask courses (get_ml_task_runs)	3562
Annuler l'MLTaskexécution (cancel_ml_task_run)	3563
StartExportLabelsTaskRun (start_export_labels_task_run)	3564
StartImportLabelsTaskRun (start_import_labels_task_run)	3565
Qualité des données	3567
— les types de données —	3567
DataSource	3568
DataQualityRulesetListDetails	3568
DataQualityTargetTable	3569
DataQualityRulesetEvaluationRunDescription	3569
DataQualityRulesetEvaluationRunFilter	3570
DataQualityEvaluationRunAdditionalRunOptions	3570
DataQualityRuleRecommendationRunDescription	3571
DataQualityRuleRecommendationRunFilter	3571
DataQualityResult	3572
DataQualityAnalyzerResult	3573
DataQualityObservation	3574
MetricBasedObservation	3575
DataQualityMetricValues	3575
DataQualityRuleResult	3576
DataQualityResultDescription	3577
DataQualityResultFilterCriteria	3578
DataQualityRulesetFilterCriteria	3578
DataQualityAggregatedMetrics	3579
StatisticAnnotation	3580
TimestampedInclusionAnnotation	3580
AnnotationError	3581
DatapointInclusionAnnotation	3581
StatisticSummaryList	3582
StatisticSummary	3582

RunIdentifier	3583
StatisticModelResult	3583
— operations —	3584
StartDataQualityRulesetEvaluationRun (start_data_quality_ruleset_evaluation_run)	3585
CancelDataQualityRulesetEvaluationRun (cancel_data_quality_ruleset_evaluation_run)	3587
GetDataQualityRulesetEvaluationRun (get_data_quality_ruleset_evaluation_run)	3588
ListDataQualityRulesetEvaluationRuns (list_data_quality_ruleset_evaluation_runs)	3590
StartDataQualityRuleRecommendationRun (start_data_quality_rule_recommendation_run)	3591
CancelDataQualityRuleRecommendationRun (cancel_data_quality_rule_recommendation_run)	3592
GetDataQualityRuleRecommendationRun (get_data_quality_rule_recommendation_run) ..	3593
ListDataQualityRuleRecommendationRuns (list_data_quality_rule_recommendation_runs)	3595
GetDataQualityResult (get_data_quality_result)	3596
BatchGetDataQualityResult (batch_get_data_quality_result)	3598
ListDataQualityResults (liste_données_qualité_résultats)	3599
CreateDataQualityRuleset (create_data_quality_ruleset)	3599
DeleteDataQualityRuleset (delete_data_quality_ruleset)	3601
GetDataQualityRuleset (get_data_quality_ruleset)	3602
ListDataQualityRulesets (liste_data_quality_rulesets)	3603
UpdateDataQualityRuleset (ensemble de règles de qualité des données de mise à jour) ...	3604
ListDataQualityStatistics (liste_données_qualité_statistiques)	3605
TimestampFilter	3606
CreateDataQualityRulesetRequest	3607
GetDataQualityRulesetResponse	3608
GetDataQualityResultResponse	3609
StartDataQualityRuleRecommendationRunRequest	3611
GetDataQualityRuleRecommendationRunResponse	3611
BatchPutDataQualityStatisticAnnotation (batch_put_data_quality_statistic_annotation)	3613
GetDataQualityModel (get_data_quality_model)	3614
GetDataQualityModelResult (get_data_quality_model_result)	3615
ListDataQualityStatisticAnnotations (list_data_quality_statistic_annotations)	3616
PutDataQualityProfileAnnotation (put_data_quality_profile_annotation)	3617
Données sensibles	3617
— les types de données —	3617
CustomEntityType	3618
— operations —	3618

CreateCustomEntityType (créer_custom_entity_type)	3618
DeleteCustomEntityType (supprimer_type_entité_personnalisé)	3620
GetCustomEntityType (get_custom_entity_type)	3621
BatchGetCustomEntityTypes (batch_get_custom_entity_types)	3622
ListCustomEntityTypes (list_custom_entity_types)	3622
Balisage APIs	3623
– types de données –	3623
Tag	3623
— operations —	3624
TagResource (tag_ressource)	3624
UntagResource (untag_resource)	3625
GetTags (get_tags)	3625
Types de données courants	3626
Tag	3626
DecimalNumber	3627
ErrorDetail	3627
PropertyPredicate	3627
ResourceUri	3628
ColumnStatistics	3628
ColumnStatisticsError	3629
ColumnError	3629
ColumnStatisticsData	3630
BooleanColumnStatisticsData	3630
DateColumnStatisticsData	3631
DecimalColumnStatisticsData	3631
DoubleColumnStatisticsData	3632
LongColumnStatisticsData	3632
StringColumnStatisticsData	3633
BinaryColumnStatisticsData	3633
Modèles de chaîne	3634
Exceptions	3636
AccessDeniedException	3637
AlreadyExistsException	3637
ConcurrentModificationException	3637
ConcurrentRunsExceededException	3637
CrawlerNotRunningException	3638

CrawlerRunningException	3638
CrawlerStoppingException	3638
EntityNotFoundException	3638
FederationSourceException	3639
FederationSourceRetryableException	3639
GlueEncryptionException	3639
IdempotentParameterMismatchException	3640
IllegalWorkflowStateException	3640
InternalServiceException	3640
InvalidExecutionEngineException	3640
InvalidInputException	3641
InvalidStateException	3641
InvalidTaskStatusTransitionException	3641
JobDefinitionErrorException	3641
JobRunInTerminalStateException	3642
JobRunInvalidStateTransitionException	3642
JobRunNotInTerminalStateException	3642
LateRunnerException	3643
NoScheduleException	3643
OperationTimeoutException	3643
ResourceNotReadyException	3643
ResourceNumberLimitExceededException	3644
SchedulerNotRunningException	3644
SchedulerRunningException	3644
SchedulerTransitioningException	3644
UnrecognizedRunnerException	3645
ValidationException	3645
VersionMismatchException	3645
AWS Glue Exemples de code d'API	3646
Principes de base	3656
Bonjour AWS Glue	3657
Principes de base	3667
Actions	3803
Sécurité	3948
Protection des données	3949
Chiffrement de données au repos	3949

chiffrement des données en transit	3968
Conformité FIPS	3968
Gestion des clés	3968
AWS Glue dépendance à l'égard d'autres AWS services	3969
Points de terminaison de développement	3969
Gestion des identités et des accès	3970
Public ciblé	3971
Authentification par des identités	3972
Gestion des accès à l'aide de politiques	3976
Comment AWS Glue fonctionne avec IAM	3979
Configuration des autorisations IAM pour AWS Glue	3987
AWS Exemples de politiques de contrôle d'accès Glue	4022
Octroi de politiques AWS gérées	4048
Spécification AWS Glue Ressource ARNs	4058
Octroi d'un accès intercompte	4068
Résolution des problèmes	4075
AWS Lake Formation modèles de contrôle d'accès	4077
Utilisation de AWS Glue with AWS Lake Formation pour un accès complet à la table	4078
Lake Formation pour le FGAC	4090
Utilisation d'Amazon S3 Access Grants avec AWS Glue	4103
Comment AWS Glue fonctionne le S3 Access Grants	4103
Considérations relatives aux subventions d'accès S3 avec AWS Glue	4104
Configurez les autorisations d'accès S3 avec AWS Glue	4105
Journalisation et surveillance	4107
Validation de conformité	4108
Résilience	4109
Sécurité de l'infrastructure	4110
Configuration des points de terminaison VPC de l'interface () pour AWS PrivateLinkAWS Glue	4110
Configuration d'Amazon partagé VPCs	4113
Résolution des problèmes AWS Glue	4114
Collecte d'informations AWS Glue de dépannage	4114
Dépannage des erreurs Spark	4115
Erreur : Ressource non disponible	4116
Erreur : Impossible de trouver le point de terminaison S3 ou la passerelle NAT du subnetId dans VPC	4116

Erreur : Règle de trafic entrant obligatoire dans le groupe de sécurité	4117
Erreur : Règle de trafic sortant obligatoire dans le groupe de sécurité	4117
Erreur : L'exécution du Job a échoué car le rôle transmis doit être autorisé à assumer le rôle pour le AWS Glue service	4117
Erreur : l' DescribeVpcEndpoints action n'est pas autorisée. impossible de valider l'ID VPC vpc-id	4118
Erreur : l' DescribeRouteTables action n'est pas autorisée. impossible de valider l'identifiant du sous-réseau : ID du sous-réseau dans l'identifiant du VPC : vpc-id	4118
Erreur : Impossible d'appeler ec2 : DescribeSubnets	4118
Erreur : Impossible d'appeler ec2 : DescribeSecurityGroups	4118
Erreur : Impossible de trouver le sous-réseau pour la zone de disponibilité	4118
Erreur : Exception d'exécution de tâche lors d'écriture sur une cible JDBC	4118
Erreur : Amazon S3 : l'opération n'est pas valide pour la classe de stockage de l'objet	4119
Erreur : Délai Amazon S3	4120
Erreur : Accès à Amazon S3 refusé	4120
Erreur : L'identifiant de la clé d'accès Amazon S3 n'existe pas	4120
Erreur : l'exécution d'une tâche échoue lors de l'accès à Amazon S3 avec un URI s3a ://	4121
Erreur : Le jeton de service Amazon S3 a expiré	4123
Erreur : Aucun DNS privé trouvé pour l'interface réseau	4123
Erreur : Échec de l'allocation du point de terminaison de développement	4123
Erreur : Serveur de bloc-notes CREATE_FAILED	4123
Erreur : Échec du démarrage du bloc-notes local	4124
Erreur : Échec de l'exécution du crawler	4124
Erreur : les partitions n'ont pas été mises à jour	4124
Erreur : la mise à jour du signet de tâche a échoué en raison d'une incompatibilité de version	4125
Erreur : Une tâche retraite des données lorsque les signets de tâche sont activés	4125
Erreur : comportement de basculement entre VPCs AWS Glue	4127
Erreurs du robot d'exploration lorsque le robot utilise les autorisations de Lake Formation	4128
Erreur : l'emplacement S3 : s3://examplepath n'est pas enregistré	4128
Erreur : L'utilisateur/le rôle n'est pas autorisé à exécuter : lakeformation : on resource GetDataAccess	4128
Erreur : autorisation(s) insuffisante(s) sur Lake Formation (nom de la base de données : ExampleDatabase, nom de la table : ExampleTable)	4128
Erreur : autorisation(s) insuffisante(s) pour Lake Formation sur s3://examplepath	4129

Questions fréquemment posées sur la configuration du crawler à l'aide des informations d'identification Lake Formation	4129
Dépannage des erreurs Ray	4130
Inspection des journaux de tâches Ray	4131
Résolution des erreurs liées aux tâches Ray	4131
AWS Glue exceptions relatives à l'apprentissage automatique	4133
Annuler MLTask RunActivity	4133
Créez MLTask RunActivity	4134
Supprimer MLTransform l'activité	4135
Obtenez MLTask RunActivity	4136
Obtenez MLTask RunsActivity	4136
Obtenir de MLTransform l'activité	4136
Obtenir de MLTransforms l'activité	4136
GetSaveLocationForTransformArtifactActivity	4137
GetTaskRunArtifactActivity	4137
Publier MLTransform ModelActivity	4138
PullLatestMLTransformModelActivity	4139
PutJobMetadataForMLTransformActivité	4139
StartExportLabelsTaskRunActivity	4140
StartImportLabelsTaskRunActivity	4140
Démarrer MLEvaluation TaskRunActivity	4141
Démarrer MLLabeling SetGenerationTaskRunActivity	4142
MLTransformActivité de mise à jour	4143
AWS Glue quotas	4144
Améliorer les AWS Glue performances	4146
Adapter les stratégies à votre type de travail	4146
Amélioration de la performance Spark	4146
Optimiser les lectures avec pushdown	4147
Pushdown de prédicat sur les fichiers stockés dans Amazon S3	4147
Pushdown lors de l'utilisation de sources JDBC	4149
Remarques et limites relatives au pushdown dans Glue AWS	4151
Utilisation de la mise à l'échelle automatique pour AWS Glue	4152
Prérequis	4153
Activer Auto Scaling dans AWS Glue Studio	1888
Activation de l'Auto Scaling avec la AWS CLI ou le SDK	1889
Activer Auto Scaling avec des sessions interactives	4155

Conseils et considérations	4155
Surveillance d'Auto Scaling à l'aide CloudWatch des métriques Amazon	4156
Surveillance de l'Auto Scaling avec Amazon CloudWatch Logs	4157
Surveillance de Auto Scaling avec Spark UI	4158
Surveillance de l'utilisation du DPU d'exécution de la tâche Auto Scaling	4159
Limites	4159
Partitionnement de la charge de travail avec exécution limitée	4159
Activation du partitionnement de la charge de travail	4160
Configuration d'un AWS Glue déclencheur pour exécuter automatiquement la tâche	4161
Problèmes connus	4162
Interdiction d'accès aux données inter-tâches	4162
Historique de la documentation	4165
Mises à jour antérieures	4238
AWS Glossaire	4240
.....	mmmmccxli

Qu'est-ce que c'est AWS Glue ?

AWS Glue est un service d'intégration de données sans serveur qui permet aux utilisateurs d'outils d'analyse de découvrir, de préparer, de déplacer et d'intégrer facilement des données provenant de sources multiples. Vous pouvez l'utiliser pour l'analyse, le machine learning et le développement d'applications. Il inclut également des outils de productivité et d'exploitation des données supplémentaires pour la création, l'exécution de tâches et la mise en œuvre de flux de travail.

Avec AWS Glue, vous pouvez découvrir et vous connecter à plus de 70 sources de données différentes et gérer vos données dans un catalogue de données centralisé. Vous pouvez créer, exécuter et surveiller visuellement des pipelines d'extraction, de transformation et de chargement (ETL) pour charger les données dans vos lacs de données. Vous pouvez également rechercher et interroger immédiatement les données cataloguées à l'aide d'Amazon Athena, Amazon EMR et Amazon Redshift Spectrum.

AWS Glue consolide les principales fonctionnalités d'intégration de données en un seul service. Il s'agit notamment de la découverte de données, de l'ETL moderne, du nettoyage, de la transformation et du catalogage centralisé. Il est également sans serveur, ce qui signifie qu'il n'y a aucune infrastructure à gérer. Avec un support flexible pour toutes les charges de travail telles que l'ETL, l'ELT et le streaming dans un seul service, AWS Glue prend en charge les utilisateurs pour différents types de charges de travail et types d'utilisateurs.

En outre, AWS Glue facilite l'intégration des données au sein de votre architecture. Il s'intègre aux services AWS d'analyse et aux lacs de données Amazon S3. AWS Glue propose des interfaces d'intégration et des outils de création de tâches faciles à utiliser pour tous les utilisateurs, des développeurs aux utilisateurs professionnels, avec des solutions adaptées à des compétences techniques variées.

Grâce à la capacité de s'adapter à la demande, AWS Glue vous aide à vous concentrer sur les activités à forte valeur ajoutée qui maximisent la valeur de vos données. Il s'adapte à toutes les tailles de données et prend en charge tous les types de données et toutes les variances de schéma. Pour accroître l'agilité et optimiser les coûts, AWS Glue fournit une haute disponibilité et une pay-as-you-go facturation intégrées.

Pour plus d'informations sur les tarifs, voir [AWS Glue tarification](#).

AWS Glue Studio

AWS Glue Studio est une interface graphique qui facilite la création, l'exécution et le suivi des tâches d'intégration de données dans AWS Glue. Vous pouvez composer visuellement des flux de transformation de données et les exécuter de manière transparente sur le moteur ETL sans serveur basé sur Apache Spark de AWS Glue.

Avec AWS Glue Studio, vous pouvez créer et gérer des tâches qui collectent, transforment et nettoient les données. Vous pouvez également utiliser AWS Glue Studio pour résoudre les problèmes et modifier les scripts de travail.

Rubriques

- [AWS Glue fonctionnalités](#)
- [En savoir plus sur les innovations dans AWS Glue](#)
- [Démarrage avec AWS Glue](#)
- [Accès AWS Glue](#)
- [Services connexes](#)

AWS Glue fonctionnalités

AWS Glue les fonctionnalités se répartissent en trois grandes catégories :

- Découvrez et organisez les données
- Transformez, préparez et nettoyez les données pour les analyser
- Créez et surveillez des pipelines de données

Découverte et organisation des données

- Unifiez et recherchez dans plusieurs banques de données : stockez, indexez et recherchez dans plusieurs sources et récepteurs de données en cataloguant toutes vos données. AWS
- Découverte automatique des données — Utilisation AWS Glue des robots d'exploration pour déduire automatiquement les informations du schéma et les intégrer dans votre AWS Glue Data Catalog
- Gestion des schémas et des autorisations— Validez et contrôlez l'accès à vos bases de données et tables.

- Connectez-vous à une grande variété de sources de données : exploitez plusieurs sources de données, sur site et en ligne AWS, en utilisant AWS Glue connexions pour créer votre lac de données.

Transformez, préparez, et nettoyez les données afin de les analyser

- Transformez visuellement les données à l'aide d'une interface de canevas de tâches : définissez votre processus ETL dans l'éditeur visuel de tâches et générez automatiquement le code pour extraire, transformer et charger vos données.
- Créez des pipelines ETL complexes avec une planification simple des tâches — Invoke AWS Glue des emplois selon un calendrier, à la demande ou en fonction d'un événement.
- Nettoyez et transformez les données de streaming en transit— Permettez une consommation continue des données, nettoyez-les et transformez-les en transit. Cette démarche le rend disponible afin de l'analyser en quelques secondes dans votre magasin de données cible.
- Dédupliquez et nettoyez les données grâce au machine learning intégré— Nettoyez et préparez vos données pour analyse sans devenir un expert en machine learning en utilisant le `FindMatches` fonction. Cette fonctionnalité permet la déduplication ainsi que la recherche des enregistrements ne correspondant pas parfaitement les uns aux autres.
- Carnets de notes de travail intégrés — AWS Glue les blocs-notes de travail fournissent des blocs-notes sans serveur avec une configuration minimale dans AWS Glue afin que vous puissiez démarrer rapidement.
- Modifiez, déboguez et testez le code ETL, avec AWS Glue sessions interactives, vous pouvez explorer et préparer des données de manière interactive. Grâce à l'IDE ou à un bloc-notes de votre choix, vous pouvez explorer, expérimenter ainsi que traiter des données de manière interactive.
- Définissez, détectez et corrigez les données sensibles : AWS Glue la détection des données sensibles vous permet de définir, d'identifier et de traiter les données sensibles dans votre pipeline de données et dans votre lac de données.

Création et surveillance des pipelines de données

- Adaptation automatique en fonction de la charge— Augmentez et diminuez les ressources de manière dynamique en fonction de la charge Cette adaptation affecte les travailleurs à des emplois uniquement en cas de nécessité.

- Automatisez les tâches à l'aide de déclencheurs basés sur des événements : lancez des robots d'exploration ou AWS Glue des tâches avec des déclencheurs basés sur des événements, et concevez une chaîne de tâches dépendantes et de robots d'exploration.
- Exécuter et surveiller les tâches — Exécuter AWS Glue jobs avec le moteur de votre choix, Spark ou Ray. Surveillez-les à l'aide d'outils de surveillance automatisés, AWS Glue Job Run Insights, et AWS CloudTrail. Améliorez votre surveillance des tâches soutenues par Spark avec l'interface utilisateur Apache Spark.
- Définition des flux de travail pour les activités ETL et d'intégration— Définissez les flux de travail pour l'ETL et les activités d'intégration pour plusieurs robots d'exploration, tâches et déclencheurs.

En savoir plus sur les innovations dans AWS Glue

Découvrez les dernières innovations AWS Glue et découvrez comment les clients les utilisent AWS Glue pour permettre la préparation des données en libre-service au sein de leur organisation.

Découvrez comment les clients évoluent AWS Glue au-delà de la configuration traditionnelle et comment ils se configurent AWS Glue pour le suivi des tâches et les performances.

Démarrage avec AWS Glue

La lecture de ces sections est indispensable:

- [Vue d'ensemble de l'utilisation AWS Glue](#)
- [AWS Glue concepts](#)
- [Configuration des autorisations IAM pour AWS Glue](#)
- [Commencer à utiliser le AWS Glue Data Catalog](#)
- [Rédaction d'emplois dans AWS Glue](#)
- [Commencer avec AWS Glue sessions interactives](#)
- [Orchestration dans AWS Glue](#)

Accès AWS Glue

Vous pouvez créer, consulter et gérer votre AWS Glue tâches utilisant les interfaces suivantes :

- **AWS Glue console** — Fournit une interface Web vous permettant de créer, de visualiser et de gérer votre AWS Glue emplois. Pour accéder à la console, voir [AWS Glue](#).
- **AWS Glue Studio**— Fournit une interface graphique vous permettant de créer et de modifier votre AWS Glue emplois visuels. Pour de plus amples informations, veuillez consulter [Création de tâches ETL visuelles avec AWS Glue Studio](#).
- **AWS Glue section de la AWS CLI référence** — Fournit des AWS CLI commandes que vous pouvez utiliser avec AWS Glue. Pour plus d'informations, consultez la section [AWS CLI Référence pour AWS Glue](#).
- **AWS Glue API** — Fournit une référence d'API complète pour les développeurs. Pour plus d'informations, consultez [.AWS Glue API](#).

Services connexes

Utilisateurs de AWS Glue utilisent également :

- [AWS Lake Formation](#)— Un service qui est une couche d'autorisation qui fournit un contrôle d'accès précis aux ressources du AWS Glue Data Catalog.
- [AWS Glue DataBrew](#)— Outil visuel de préparation des données que vous pouvez utiliser pour nettoyer et normaliser les données sans écrire de code.

AWS Glue : comment ça marche

AWS Glue utilise d'autres AWS services pour orchestrer vos tâches ETL (extraction, transformation et chargement) afin de créer des entrepôts de données et des lacs de données et de générer des flux de sortie. AWS Glue appelle les opérations d'API pour transformer vos données, créer des journaux d'exécution, stocker la logique de vos tâches et créer des notifications pour vous aider à surveiller l'exécution de vos tâches. Le AWS Glue La console connecte ces services à une application gérée, afin que vous puissiez vous concentrer sur la création et le suivi de votre travail ETL. La console effectue les opérations de développement et de tâches administratives en votre nom. Vous fournissez des informations d'identification et d'autres propriétés à AWS Glue pour accéder à vos sources de données et écrire sur vos cibles de données.

AWS Glue prend en charge le provisionnement et la gestion des ressources nécessaires à l'exécution de votre charge de travail. Vous n'avez pas besoin de créer l'infrastructure d'un outil ETL car AWS Glue le fait pour toi. Lorsque des ressources sont requises, afin de réduire le temps de démarrage, AWS Glue utilise une instance de son pool d'instances chaud pour exécuter votre charge de travail.

Avec AWS Glue, vous créez des tâches à l'aide des définitions de tables de votre catalogue de données. Les tâches consistent en des scripts contenant les instructions qui exécutent les tâches de transformation de données souhaitées. Vous pouvez utiliser des déclencheurs pour initier des tâches sur un calendrier ou en tant que résultat d'un événement spécifié. Vous déterminez où résident vos données cible et les données source qui alimentent votre cible. Sur la base de vos contributions, AWS Glue transforme vos données du format source au format cible. Vous pouvez également fournir des scripts personnalisés dans AWS Glue console ou API pour traiter vos données en fonction de vos besoins spécifiques.

Sources et destinations des données

AWS Glue for Spark vous permet de lire et d'écrire des données provenant de plusieurs systèmes et bases de données, notamment :

- Amazon S3
- Amazon DynamoDB
- Amazon Redshift
- Amazon Relational Database Service (Amazon RDS)
- Bases de données tierces accessibles à JDBC

- MongoDB et Amazon DocumentDB (compatible avec MongoDB)
- Autres connecteurs de place de marché et plug-ins Apache Spark

Flux de données

AWS Glue for Spark peut diffuser des données à partir des systèmes suivants :

- Amazon Kinesis Data Streams
- Apache Kafka

AWS Glue est disponible dans plusieurs AWS régions. Pour de plus amples informations, veuillez consulter [AWS Régions et points de terminaison](#) dans le manuel Référence générale d'Amazon Web Services.

Rubriques

- [Travaux ETL sans serveur exécutés en isolation](#)
- [AWS Glue concepts](#)
- [AWS Glue composants](#)
- [AWS Glue pour Spark et AWS Glue pour Ray](#)
- [Conversion de schémas semi-structurés en schémas relationnels avec AWS Glue](#)
- [AWS Systèmes de type Glue](#)

Travaux ETL sans serveur exécutés en isolation

AWS Glue exécute vos tâches ETL dans un environnement sans serveur avec le moteur de votre choix, Spark ou Ray. AWS Glue exécute ces tâches sur des ressources virtuelles qu'il fournit et gère dans son propre compte de service.

AWS Glue est conçu pour effectuer les opérations suivantes :

- Isoler les données clients.
- Protéger les données client en transit et au repos.
- Accéder aux données des clients uniquement en cas de besoin, en réponse à leurs demandes, à l'aide d'informations d'identification temporaires et réduites, ou aux rôles IAM de leur compte lorsqu'ils y consentent.

Lors de la mise en service d'une tâche ETL, vous fournissez des sources de données d'entrée et des cibles de données de sortie dans votre cloud privé virtuel (VPC). En outre, vous fournissez le rôle IAM, l'ID VPC, l'ID de sous-réseau et le groupe de sécurité nécessaires pour accéder aux sources et aux cibles de données. Pour chaque tuple (ID de compte client, rôle IAM, ID de sous-réseau et groupe de sécurité), AWS Glue crée un nouvel environnement isolé au niveau du réseau et de la gestion de tous les autres environnements de votre AWS Glue compte de service.

Vous créez et configurez AWS Glue des ressources, telles que des catalogues de données, des tâches et des robots d'exploration au sein de votre AWS compte. Ces ressources sont ensuite associées au rôle IAM et aux paramètres réseau (sous-réseau et groupe de sécurité) que vous spécifiez lors du processus de création.

AWS Glue crée des interfaces réseau élastiques dans votre sous-réseau à l'aide d'adresses IP privées. Les tâches utilisent ces interfaces réseau élastiques pour accéder à vos sources et à vos cibles de données. Le trafic entrant, sortant et au sein de l'environnement d'exécution des tâches est régi par votre VPC et vos politiques réseau, à une exception près : les appels passés à AWS Glue les bibliothèques peuvent rediriger le trafic vers AWS Glue Opérations d'API via le AWS Glue VPC. Tous les appels d'API sont enregistrés ; les propriétaires des données peuvent donc auditer l'accès aux API en activant [AWS CloudTrail](#), ce qui fournit des journaux d'audit à votre compte.

AWS Glue les environnements gérés qui exécutent vos tâches ETL sont protégés par les mêmes pratiques de sécurité que celles appliquées AWS aux autres services. Pour un aperçu des pratiques et des responsabilités partagées en matière de sécurité, consultez le livre blanc [Introduction aux processus AWS de sécurité](#).

AWS Glue concepts

AWS Glue est un service ETL (extraction, transformation, chargement) entièrement géré qui vous permet de déplacer facilement des données entre différentes sources de données et cibles. Les principaux composants sont les suivants :


- Catalogue de données : magasin de métadonnées contenant des définitions de tables, des définitions de tâches et d'autres informations de contrôle pour vos flux de travail ETL.
- Crawlers : programmes qui se connectent à des sources de données, déduisent des schémas de données et créent des définitions de tables de métadonnées dans le catalogue de données.
- Tâches ETL : logique métier permettant d'extraire les données des sources, de les transformer à l'aide de scripts Apache Spark et de les charger dans des cibles.

- Déclencheurs : mécanismes permettant de lancer des exécutions de tâches en fonction de calendriers ou d'événements.

Le flux de travail typique implique :

1. Définissez les sources de données et les cibles dans le catalogue de données.
2. Utilisez les robots d'exploration pour renseigner le catalogue de données avec des métadonnées de table provenant de sources de données.
3. Définissez des tâches ETL avec des scripts de transformation pour déplacer et traiter les données.
4. Exécutez des tâches à la demande ou en fonction de déclencheurs.
5. Surveillez les performances au travail à l'aide de tableaux de bord.

Le schéma suivant montre l'architecture d'un AWS Glue environnement.



Vous définissez des tâches AWS Glue pour accomplir le travail requis pour extraire, transformer et charger des données (ETL) d'une source de données vers une cible de données. Généralement, vous effectuez les actions suivantes :

- Pour les sources de magasins de données, vous définissez un crawler pour remplir votre AWS Glue Data Catalog avec les définitions de table des métadonnées. Vous associez votre crawler à un magasin de données, et le crawler crée les définitions de table dans le catalogue de données. Pour les sources en streaming, vous définissez manuellement les tables du catalogue de données et spécifiez les propriétés du flux des données.

Outre les définitions de tables, le AWS Glue Data Catalog contient d'autres métadonnées nécessaires pour définir les tâches ETL. Vous utilisez ces métadonnées lorsque vous définissez une tâche pour transformer vos données.

- AWS Glue peut générer un script pour transformer vos données. Vous pouvez également fournir le script dans la AWS Glue console ou dans l'API.
- Vous pouvez exécuter votre tâche à la demande ou la configurer pour qu'elle démarre lorsqu'un déclencheur spécifié est mis en action. Le déclencheur peut être une planification temporelle ou un événement.

Lorsque votre tâche s'exécute, un script extrait les données de la source de données, les transforme et les charge sur la cible de données. Le script s'exécute dans un environnement Apache Spark, dans AWS Glue.

Important

Les tables et les bases de données dans AWS Glue sont des objets dans le AWS Glue Data Catalog. Elles contiennent des métadonnées, mais aucune donnée d'un magasin de données.

Les données textuelles, telles que CSVs, doivent être codées **UTF-8** AWS Glue pour être traitées correctement. Pour plus d'informations, veuillez consulter la page Wikipédia [UTF-8](#).

AWS Glue terminologie

AWS Glue repose sur l'interaction de plusieurs composants pour créer et gérer votre flux de travail d'extraction, de transformation et de chargement (ETL).

AWS Glue Data Catalog

Les métadonnées persistantes sont stockées dans AWS Glue. Il contient des définitions de tables, des définitions de tâches et d'autres informations de contrôle pour gérer votre AWS Glue environnement. Chaque AWS compte en possède un AWS Glue Data Catalog par région.

Classifieur

Détermine le schéma de vos données. AWS Glue fournit des classificateurs pour les types de fichiers courants, tels que CSV, JSON, AVRO, XML, etc. Il fournit également les classifieurs des systèmes de gestion de base de données relationnelle (SGBDR) utilisant une connexion JDBC. Vous pouvez

écrire votre propre classifieur à l'aide d'un modèle grok ou en spécifiant une balise de ligne dans un document XML.

Connexion

Un objet de catalogue de données qui contient les propriétés requises pour se connecter à un magasin de données particulier.

crawler

Programme qui se connecte à un magasin de données (source ou cible), parcourt la liste hiérarchisée des classifieurs pour déterminer le schéma de vos données, puis crée des tables de métadonnées dans l' AWS Glue Data Catalog.

Base de données

Ensemble de définitions de tables du catalogue de données associées, organisées en un groupe logique.

Stockage de données, source de données, cible de données

Un magasin de données est un référentiel qui permet de stocker vos données de façon permanente. Les exemples incluent les compartiments Amazon S3 et les bases de données relationnelles. Une source de données est un magasin de données qui est utilisé comme entrée d'un processus ou d'une transformation. Une cible de données est un magasin de données dans lequel écrit un processus ou une transformation.

Point de terminaison de développement

Un environnement que vous pouvez utiliser pour développer et tester vos scripts AWS Glue ETL.

Trame dynamique

Table distribuée qui prend en charge les données imbriquées telles que les structures et les tableaux. Chaque enregistrement est auto-descriptif, conçu pour une flexibilité de schéma avec des données semi-structurées. Chaque enregistrement contient à la fois les données et le schéma qui les décrit. Vous pouvez utiliser à la fois des cadres dynamiques et Apache Spark DataFrames dans vos scripts ETL, et effectuer des conversions entre eux. Les trames dynamiques fournissent un ensemble de transformations avancées pour le nettoyage des données, ainsi que pour l'extraction, le transfert et le chargement.

Tâche

Logique métier requise pour exécuter un travail d'extraction, de transformation et de chargement (ETL). Elle se compose d'un script de transformation, de sources de données et de cibles de données. Les exécutions des tâches sont initiées par les déclencheurs qui peuvent être planifiés ou mis en action par des événements.

Tableau de bord de performance de tâche

AWS Glue fournit un tableau de bord d'exécution complet pour vos tâches ETL. Le tableau de bord affiche des informations sur les exécutions de tâche à partir d'une période spécifique.

Interface de bloc-notes

Une expérience de bloc-notes améliorée grâce à une configuration en un clic pour faciliter la création des tâches et l'exploration des données. Le bloc-notes et les connexions sont configurés automatiquement pour vous. Vous pouvez utiliser l'interface du bloc-notes basée sur Jupyter Notebook pour développer, déboguer et déployer des scripts et des flux de travail de manière interactive à l'aide de l'infrastructure ETL Apache Spark AWS Glue sans serveur. Vous pouvez également effectuer des requêtes ad hoc, des analyses de données et des visualisations (par exemple, des tableaux et des graphiques) dans l'environnement de bloc-notes.

Script

Code qui extrait les données des sources, les transforme et les charge dans des cibles. AWS Glue génère PySpark ou des scripts Scala.

Tableau

Définition de métadonnées qui représente vos données. Que les données se trouvent dans un fichier Amazon Simple Storage Service (Amazon S3), une table Amazon Relational Database Service (Amazon RDS) ou un autre jeu de données, une table définit le schéma de vos données. Un tableau AWS Glue Data Catalog contient les noms des colonnes, les définitions des types de données, les informations de partition et les autres métadonnées relatives à un jeu de données de base. Le schéma de vos données est représenté dans la définition de votre AWS Glue table. Les données réelles restent dans leur magasin de données d'origine, qu'il s'agisse d'un fichier ou d'une table de base de données relationnelle. AWS Glue catalogue vos fichiers et vos tables de base de données relationnelle dans le. AWS Glue Data Catalog Ils sont utilisés comme sources et cibles lorsque vous créez une tâche ETL.

Transformation

Logique de code qui permet de manipuler les données dans un format différent.

Déclencheur

Démarre une tâche ETL. Les déclencheurs peuvent être définis selon une heure planifiée ou un événement.

Éditeur de tâche visuel

L'éditeur visuel est une interface graphique qui facilite la création, l'exécution et le contrôle des tâches d'Extraction, transformation et chargement (ETL) dans AWS Glue. Vous pouvez composer visuellement des flux de travail de transformation des données, les exécuter AWS Glue de manière fluide sur le moteur ETL sans serveur basé sur Apache Spark et inspecter le schéma et les résultats des données à chaque étape du travail.

Nœuds

Avec AWS Glue, vous ne payez que pour le temps nécessaire à l'exécution de votre tâche ETL. Il n'y a pas de ressources à gérer, pas de coûts initiaux et les temps de démarrage ou d'arrêt ne vous sont pas facturés. Un taux horaire vous est facturé en fonction du nombre d'unités de traitement des données (ou DPU) utilisées pour exécuter votre tâche ETL. Une seule unité de traitement des données (DPU) est également appelée « travailleur ». AWS Glue propose trois types de travailleurs pour vous aider à sélectionner la configuration qui répond à vos exigences en matière de latence et de coûts. Les employés sont disponibles en configurations Standard, G.1X, G.2X, et G.025X.

AWS Glue composants

AWS Glue fournit une console et des opérations d'API pour configurer et gérer votre charge de travail d'extraction, de transformation et de chargement (ETL). Vous pouvez utiliser les opérations d'API via plusieurs langages spécifiques SDKs et le AWS Command Line Interface (AWS CLI). Pour plus d'informations sur l'utilisation du AWS CLI, reportez-vous à la section [Référence des AWS CLI commandes](#).

AWS Glue utilise le AWS Glue Data Catalog pour stocker les métadonnées relatives aux sources de données, aux transformations et aux cibles. Le Catalogue de données est un remplacement instantané du métastore Apache Hive. AWS Glue Jobs system Il fournit une infrastructure gérée pour définir, planifier et exécuter des opérations ETL sur vos données. Pour plus d'informations sur l' AWS Glue API, consultez [AWS Glue API](#).

AWS Glue console

Vous utilisez la AWS Glue console pour définir et orchestrer votre flux de travail ETL. La console appelle plusieurs opérations d'API dans AWS Glue Data Catalog et AWS Glue Jobs system pour effectuer les tâches suivantes :

- Définissez AWS Glue des objets tels que des tâches, des tables, des robots d'exploration et des connexions.
- Planifier l'exécution des crawlers.
- Définir les événements ou planifications des déclencheurs de tâche.
- Recherchez et filtrez des listes d' AWS Glue objets.
- Modifier les scripts de transformation.

AWS Glue Data Catalog

AWS Glue Data Catalog Il s'agit de votre magasin de métadonnées techniques permanent dans le AWS cloud.

Chaque AWS compte en possède un AWS Glue Data Catalog par AWS région. Chaque catalogue de données est un ensemble hautement évolutif de tableaux organisés en bases de données. Une table est une représentation par métadonnées d'un ensemble de données structurées ou semi-structurées stockées dans des sources telles qu'Amazon RDS, le système de fichiers distribué Apache Hadoop, Amazon OpenSearch Service, etc. AWS Glue Data Catalog Il fournit un référentiel uniforme dans lequel des systèmes disparates peuvent stocker et rechercher des métadonnées afin de suivre les données dans des silos de données. Vous pouvez ensuite utiliser les métadonnées pour interroger et transformer ces données de manière cohérente dans une grande variété d'applications.

Vous utilisez le catalogue de données ainsi que les AWS Identity and Access Management politiques et Lake Formation pour contrôler l'accès aux tables et aux bases de données. Pour ce faire, vous pouvez autoriser différents groupes de votre entreprise à publier les données en toute sécurité à l'échelle de l'organisation tout en protégeant au maximum les informations sensibles.

Le catalogue de données, ainsi que Lake Formation, vous fournissent également des fonctionnalités complètes d'audit et de gouvernance, avec un suivi des modifications de schéma et des contrôles d'accès aux données. CloudTrail Cela permet de s'assurer que les données ne sont pas modifiées de façon inappropriée ou partagées par inadvertance.

Pour plus d'informations sur la sécurisation et l'audit du AWS Glue Data Catalog, consultez :

- AWS Lake Formation – Pour en savoir plus, consultez [Présentation d' AWS Lake Formation](#) dans le Guide du développeur AWS Lake Formation .
- CloudTrail— Pour plus d'informations, voir [Qu'est-ce que c'est CloudTrail ?](#) dans le guide de AWS CloudTrail l'utilisateur.

Voici d'autres AWS services et projets open source qui utilisent : AWS Glue Data Catalog

- Amazon Athena – Pour plus d'informations, veuillez consulter la rubrique [Présentation des tables, des bases de données et du catalogue de données](#) dans le Guide de l'utilisateur Amazon Athena.
- Amazon Redshift Spectrum Pour en savoir plus, consultez la rubrique [Utilisation d'Amazon Redshift Spectrum pour interroger des données externes](#) dans le Guide du développeur de base de données Amazon Redshift.
- Amazon EMR - Pour plus d'informations, veuillez consulter la rubrique [Utiliser de stratégies basées sur les ressources pour l'accès d'Amazon EMR à AWS Glue Data Catalog](#) dans le Guide de gestion Amazon EMR.
- AWS Glue Data Catalog client pour le métastore Apache Hive — Pour plus d'informations sur ce GitHub projet, voir [AWS Glue Data Catalog Client pour le métastore Apache Hive](#).

AWS Glue chenilles et classificateurs

AWS Glue vous permet également de configurer des robots d'exploration capables de scanner les données dans toutes sortes de référentiels, de les classer, d'en extraire des informations de schéma et de stocker les métadonnées automatiquement dans le. AWS Glue Data Catalog Ils AWS Glue Data Catalog peuvent ensuite être utilisés pour guider les opérations ETL.

Pour de plus amples informations sur la configuration des crawlers et des classifieurs, veuillez consulter [Utilisation de robots d'exploration pour alimenter le catalogue de données](#) . Pour plus d'informations sur la programmation des robots d'exploration et des classificateurs à l'aide de l' AWS Glue API, consultez. [API de classifieurs et d'crawlers](#)

AWS Glue Opérations ETL

À l'aide des métadonnées du catalogue de données, AWS Glue vous pouvez générer automatiquement des scripts Scala ou PySpark (l'API Python pour Apache Spark) avec des AWS Glue extensions que vous pouvez utiliser et modifier pour effectuer diverses opérations ETL. Par

exemple, vous pouvez extraire, nettoyer et transformer les données brutes, puis stocker le résultat dans un référentiel différent, où il peut être interrogé et analysé. Un tel script peut convertir un fichier CSV sous une forme relationnelle et l'enregistrer dans Amazon Redshift.

Pour plus d'informations sur l'utilisation des fonctionnalités AWS Glue ETL, consultez [Programmation de scripts Spark](#).

Streaming d'ETL en AWS Glue

AWS Glue vous permet d'effectuer des opérations ETL sur des données en streaming à l'aide de tâches exécutées en continu. AWS Glue L'ETL de streaming repose sur le moteur de streaming structuré Apache Spark et peut ingérer des flux provenant d'Amazon Kinesis Data Streams, d'Apache Kafka et d'Amazon Managed Streaming for Apache Kafka (Amazon MSK). ETL de streaming peut nettoyer et transformer les données de streaming et les charger dans des magasins de données Amazon S3 ou JDBC. Utilisez Streaming ETL in AWS Glue pour traiter les données d'événements telles que les flux IoT, les flux de clics et les journaux réseau.

Si vous connaissez le schéma de la source de données de streaming, vous pouvez le spécifier dans une table du catalogue de données. Sinon, vous pouvez activer la détection de schéma dans la tâche ETL de streaming. La tâche détermine ensuite automatiquement le schéma à partir des données entrantes.

La tâche ETL de streaming peut utiliser à la fois des transformations AWS Glue intégrées et des transformations natives d'Apache Spark Structured Streaming. Pour plus d'informations, consultez la section [Opérations sur le DataFrames streaming/Datasets](#) sur le site Web d'Apache Spark.

Pour de plus amples informations, veuillez consulter [the section called “Tâches ETL en streaming”](#).


Le système AWS Glue d'emplois

AWS Glue Jobs system Il fournit une infrastructure gérée pour orchestrer votre flux de travail ETL. Vous pouvez créer des tâches AWS Glue qui automatisent les scripts que vous utilisez pour extraire, transformer et transférer des données vers différents emplacements. Les tâches peuvent être programmées et chaînées, ou elles peuvent être déclenchées par des événements tels que l'arrivée de nouvelles données.

Pour plus d'informations sur l'utilisation du AWS Glue Jobs system, consultez [Surveillance AWS Glue](#). Pour plus d'informations sur la programmation à l'aide de l'API AWS Glue Jobs system, consultez [API de tâches](#).

Composants ETL visuels

AWS Glue vous permet de créer des tâches ETL via un canevas visuel que vous pouvez manipuler.



Menu de tâches ETL

Les options du menu situées en haut du canevas vous permettent d'accéder aux différentes vues et aux détails de configuration de votre tâche.

- Visuel : le canevas de l'éditeur de tâche visuel. C'est ici que vous pouvez ajouter des nœuds pour créer une tâche.
- Script : représentation par script de votre tâche ETL. AWS Glue génère le script en fonction de la représentation visuelle de votre travail. Vous pouvez également modifier votre script ou le télécharger.

Note

Si vous choisissez de modifier le script, l'expérience de création de tâches est définitivement convertie en mode script uniquement. Ensuite, vous ne pourrez plus utiliser l'éditeur visuel pour modifier la tâche. Vous devez ajouter toutes les sources de tâches, les transformations et les cibles, et apporter toutes les modifications nécessaires à l'aide de l'éditeur visuel avant de choisir de modifier le script.

- **Détails de la tâche** : l'onglet Détails de la tâche vous permet de configurer votre tâche en définissant les propriétés de la tâche. Il existe des propriétés de base, telles que le nom et la description de votre travail, le rôle IAM, le type de travail, la version de AWS Glue, la langue, le type de travailleur, le nombre de travailleurs, le signet du travail, l'exécution flexible, le nombre de départs à la retraite et le délai d'expiration du travail, ainsi que des propriétés avancées, telles que les connexions, les bibliothèques, les paramètres du travail et les balises.
- **Exécutions** : après l'exécution de votre tâche, vous pouvez accéder à cet onglet pour consulter vos précédentes exécutions de tâches.
- **Qualité des données** : la qualité des données évalue et contrôle la qualité de vos ressources de données. Vous pouvez en savoir plus sur l'utilisation de la qualité des données dans cet onglet et ajouter une transformation de qualité des données à votre tâche.
- **Calendriers** : les tâches que vous avez planifiées apparaissent dans cet onglet. Si aucun calendrier n'est associé à cette tâche, cet onglet n'est pas accessible.
- **Contrôle de version** : vous pouvez utiliser Git avec votre tâche en la configurant dans un référentiel Git.

Panneaux ETL visuels

Lorsque vous travaillez dans le canevas, plusieurs panneaux sont disponibles pour vous aider à configurer vos nœuds ou à prévisualiser vos données et à visualiser le schéma de sortie.

- **Propriétés** : le panneau Propriétés apparaît lorsque vous choisissez un nœud sur votre canevas.
- **Aperçu des données** : le panneau Aperçu des données fournit un aperçu de la sortie des données afin que vous puissiez prendre des décisions avant d'exécuter votre tâche et d'examiner votre sortie.
- **Schéma de sortie** : l'onglet Schéma de sortie vous permet de visualiser et de modifier le schéma de vos nœuds de transformation.

Redimensionnement des panneaux


Vous pouvez redimensionner le panneau Propriétés sur le côté droit de l'écran et le panneau inférieur qui contient les onglets Aperçu des données et Schéma de sortie en cliquant sur le bord du panneau et en le faisant glisser vers la gauche et la droite ou vers le haut et le bas.

- **Panneau Propriétés** : redimensionnez le panneau Propriétés en cliquant et en faisant glisser le bord du canevas sur le côté droit de l'écran, puis en le faisant glisser vers la gauche pour augmenter sa largeur. Par défaut, le panneau est réduit et lorsqu'un nœud est sélectionné, le panneau Propriétés s'ouvre à sa taille par défaut.
- **Panneau Aperçu des données et Schéma de sortie** : redimensionnez le panneau inférieur en cliquant et en faisant glisser le bord inférieur du canevas en bas de l'écran, puis en le faisant glisser vers le haut pour augmenter sa hauteur. Par défaut, le panneau est réduit et lorsqu'un nœud est sélectionné, le panneau inférieur s'ouvre à sa taille par défaut.

Canevas de tâche

Vous pouvez ajouter, supprimer et déplacer/réorganiser des nœuds directement sur le canevas ETL visuel. Considérez-le comme votre espace de travail pour créer une tâche ETL entièrement fonctionnelle qui commence par une source de données et peut se terminer par une cible de données.


Lorsque vous travaillez avec des nœuds sur le canevas, vous disposez d'une barre d'outils qui vous permet d'effectuer des zooms avant et arrière, de supprimer des nœuds, d'établir ou de modifier des connexions entre les nœuds, de modifier l'orientation du flux de travail et d'annuler ou de rétablir une action.



La barre d'outils flottante est ancrée dans le coin supérieur droit du canevas et contient plusieurs images qui effectuent des actions :

- Icône de mise en page : la première icône de la barre d'outils est l'icône de mise en page. Par défaut, la direction des tâches visuelles est de haut en bas. Elle réorganise la direction de votre tâche visuelle en disposant les nœuds horizontalement de gauche à droite. Cliquez à nouveau sur l'icône de mise en page pour revenir de haut en bas.
- Icône de recentrage : l'icône de recentrage modifie l'affichage du canevas en le centrant. Vous pouvez l'utiliser pour des tâches importantes pour revenir à la position centrale.
- Icône de zoom avant : l'icône de zoom avant agrandit la taille des nœuds du canevas.
- Icône de zoom arrière : l'icône de zoom avant réduit la taille des nœuds du canevas.
- Icône corbeille : l'icône de corbeille supprime un nœud de la tâche visuelle. Vous devez d'abord sélectionner un nœud.
- Icône d'annulation : l'icône d'annulation annule la dernière action effectuée sur la tâche visuelle.
- Icône de rétablissement : l'icône de rétablissement répète la dernière action effectuée sur la tâche visuelle.

Utilisation de la mini-carte



Panneau des ressources

Le panneau des ressources contient toutes les sources de données, les actions de transformation et les connexions disponibles. Ouvrez le panneau des ressources sur le canevas en cliquant sur l'icône « + ». Cela ouvre le panneau des ressources.

Pour fermer le panneau des ressources, cliquez sur la croix, X, dans le coin supérieur droit du panneau des ressources. Le panneau est ainsi masqué jusqu'à ce que vous souhaitiez l'ouvrir à nouveau.

+ Add nodes

▼ Popular transforms & data

 Amazon S3 (source)

 Amazon Redshift (source)

 Change Schema

 Join

 SQL Query

 Aggregate

 Custom Transform

 Filter

Transforms

Data

▼ Sources



AWS Glue Data Catalog
AWS Glue Data Catalog table as the data source.



Amazon S3
JSON, CSV, or Parquet files stored in S3.



Amazon Kinesis
Read from an Amazon Kinesis Data Stream.



Apache Kafka
Read from an Apache Kafka or Amazon MSK topic.



Relational DB
AWS Glue Data Catalog table with a relational database as the data source.



Amazon Redshift
Read your data from Amazon Redshift.



MySQL
AWS Glue Data Catalog table with MySQL as the data source.



PostgreSQL
AWS Glue Data Catalog table with PostgreSQL as the data source.



Oracle SQL
AWS Glue Data Catalog table with Oracle SQL as the data source.



Microsoft SQL Server
AWS Glue Data Catalog table with SQL Server as the data source.



Amazon DynamoDB
AWS Glue Data Catalog table with DynamoDB as the data source.



Snowflake
Read your data from Snowflake.

Transformations et données populaires

En haut du panneau se trouve une collection de Transformations et de données populaires. Ces nœuds sont couramment utilisés dans AWS Glue. Choisissez-en un pour l'ajouter au canevas. Vous pouvez également masquer les Transformations et données populaires en cliquant sur le triangle situé à côté de l'en-tête Transformations et données populaires.

Dans la section Transformations et données populaires, vous pouvez rechercher des nœuds de transformations et de source de données. Les résultats apparaissent au fur et à mesure que vous saisissez du texte. Plus vous saisissez de caractères lors de votre requête de recherche, plus la liste des résultats diminuera. Les résultats de la recherche sont générés à partir du nom ou de la description du nœud. Choisissez un nœud pour l'ajouter à votre canevas.

Transformations et données

Deux onglets organisent les nœuds en Transformations et Données.

Transformations : lorsque vous choisissez l'onglet Transformations, toutes les transformations disponibles peuvent être sélectionnées. Choisissez une transformation pour l'ajouter au canevas. Vous pouvez également choisir Ajouter une transformation au bas de la liste des transformations, ce qui ouvrira une nouvelle page de documentation sur la création de [Transformations visuelles personnalisées](#). En suivant les étapes, vous pourrez créer vos propres transformations. Vos transformations apparaîtront alors dans la liste des transformations disponibles.

Données : l'onglet de données contient tous les nœuds des Sources et des Cibles. Vous pouvez masquer les sources et les cibles en cliquant sur le triangle situé à côté de l'en-tête sources ou cibles. Vous pouvez afficher les sources et les cibles en cliquant à nouveau sur le triangle. Choisissez un nœud source ou cible pour l'ajouter au canevas. Vous pouvez également choisir Gérer les connexions pour ajouter une nouvelle connexion. Cela ouvrira la page Connecteurs dans la console.

AWS Glue pour Spark et AWS Glue pour Ray

Dans AWS Glue Apache Spark (AWS Glue ETL), vous pouvez PySpark écrire du code Python pour gérer les données à grande échelle. Spark est une solution familière à ce problème, mais les ingénieurs de données formés à Python peuvent trouver la transition peu intuitive. Le DataFrame modèle Spark n'est pas parfaitement « pythonique », ce qui reflète le langage Scala et le runtime Java sur lesquels il repose.

Dans AWS Glue, vous pouvez utiliser des tâches shell Python pour exécuter des intégrations de données Python natives. Ces tâches s'exécutent sur une seule EC2 instance Amazon et sont limitées

par la capacité de cette instance. Elle limite le débit des données que vous pouvez traiter et devient coûteuse à gérer lorsqu'il s'agit de Big Data.

AWS Glue for Ray vous permet d'augmenter les charges de travail en Python sans investir de manière substantielle dans l'apprentissage de Spark. Vous pouvez tirer parti de certains scénarios dans lesquels Ray est plus performant. En vous offrant le choix, vous pouvez utiliser les points forts de Spark et de Ray.

AWS Glue ETL et AWS Glue for Ray sont différents en dessous, ils supportent donc des fonctionnalités différentes. Consultez la documentation pour identifier les fonctionnalités prises en charge.

Qu'est-ce que c'est AWS Glue pour Ray ?

Ray est une infrastructure de calcul distribuée open source que vous pouvez utiliser pour augmenter les charges de travail, en mettant l'accent sur Python. Pour plus d'informations sur Ray, consultez le [site Web de Ray](#). AWS Glue Les tâches de Ray et les sessions interactives vous permettent d'utiliser Ray dans Ray AWS Glue.

Vous pouvez utiliser AWS Glue for Ray pour écrire des scripts Python pour des calculs qui s'exécuteront en parallèle sur plusieurs machines. Dans les tâches et les sessions interactives Ray, vous pouvez utiliser des bibliothèques Python familières telles que Pandas, afin de faciliter l'écriture et l'exécution de vos flux de travail. Pour plus d'informations sur les jeux de données Ray, veuillez consulter la rubrique [Jeux de données Ray](#) dans la documentation Ray. Pour plus d'informations sur pandas, veuillez consulter le [site Web Pandas](#).

Avec AWS Glue for Ray, vous pouvez exécuter vos flux de travail Pandas sur des mégadonnées à l'échelle de l'entreprise, avec seulement quelques lignes de code. Vous pouvez créer une tâche Ray à partir de la AWS Glue console ou du AWS SDK. Vous pouvez également ouvrir une session AWS Glue interactive pour exécuter votre code dans un environnement Ray sans serveur. Les tâches visuelles dans ne AWS Glue Studio sont pas encore prises en charge.

AWS Glue les jobs for Ray vous permettent d'exécuter un script selon un calendrier ou en réponse à un événement d'Amazon EventBridge. Les jobs stockent des informations de journal et des statistiques de surveillance CloudWatch qui vous permettent de comprendre l'état et la fiabilité de votre script. Pour plus d'informations sur le système des AWS Glue tâches, consultez [the section called "Utilisation des tâches Ray"](#).

Ray automatise la mise à l'échelle du code Python en répartissant le traitement sur un cluster de machines qu'il reconfigure en temps réel, en fonction de la charge. Cette opération peut entraîner

une amélioration des performances par dollar pour certaines charges de travail. Avec Ray Jobs, nous avons intégré la mise à l'échelle automatique de manière native dans le modèle de AWS Glue travail, afin que vous puissiez tirer pleinement parti de cette fonctionnalité. Les travaux de Ray sont exécutés sur AWS Graviton, ce qui se traduit par une meilleure performance globale en termes de prix.

Outre les économies de coûts qu'elle permet, vous pouvez utiliser la mise à l'échelle automatique native pour exécuter les charges de travail Ray sans consacrer de temps à la maintenance, au réglage et à l'administration des clusters. Vous pouvez utiliser des bibliothèques open source familières prêtes à l'emploi, telles que Pandas, et le AWS SDK pour Pandas. Elles améliorent la vitesse d'itération pendant que vous développez sur AWS Glue pour Ray. Lorsque vous utiliserez AWS Glue for Ray, vous serez en mesure de développer et d'exécuter rapidement des charges de travail d'intégration de données rentables.

Conversion de schémas semi-structurés en schémas relationnels avec AWS Glue

Il est courant de vouloir convertir des données semi-structurées en tables relationnelles. Conceptuellement, vous aplatissez un schéma hiérarchique pour en faire un schéma relationnel. AWS Glue peut effectuer cette conversion pour vous on-the-fly.


Les données semi-structurées contiennent généralement un balisage pour identifier les entités au sein des données. Il peut inclure des structures de données imbriquées sans schéma fixe. Pour en savoir plus sur les données semi-structurées, consultez [Semi-structured data](#) dans Wikipédia.

Les données relationnelles sont représentées par des tables composées de lignes et de colonnes. Les relations entre les tables peuvent être représentées par une relation entre clé primaire et clé étrangère. Pour en savoir plus, consultez [Base de données relationnelle](#) dans Wikipedia.


AWS Glue utilise des robots d'exploration pour déduire des schémas de données semi-structurées. Il transforme ensuite les données en un schéma relationnel à l'aide d'une tâche ETL (extraction, transformation et chargement). Par exemple, vous souhaitez peut-être analyser les données JSON des fichiers source Amazon Simple Storage Service (Amazon S3) vers les tables Amazon Relational Database Service (Amazon RDS). Comprendre comment AWS Glue gère les différences entre les schémas et peut vous aider à comprendre le processus de transformation.

Ce schéma montre comment AWS Glue transforme un schéma semi-structuré en schéma relationnel.

Semi-structured schema



Relational schema



Le diagramme illustre les éléments suivants :

- La valeur unique A est convertie directement en une colonne relationnelle.
- La paire de valeurs B1 et B2 est convertie en deux colonnes relationnelles.
- La structure C et ses enfants X et Y sont convertis en deux colonnes relationnelles.
- Le tableau D[] est converti en une colonne relationnelle avec une clé étrangère qui pointe vers une autre table relationnelle. En plus d'une clé primaire, la seconde table relationnelle comporte des colonnes qui contiennent le décalage et la valeur des éléments du tableau.

AWS Systèmes de type Glue

AWS Glue utilise plusieurs types de systèmes pour fournir une interface polyvalente sur des systèmes de données qui stockent les données de manières très différentes. Ce document met fin à l'ambiguïté des systèmes de type AWS Glue et des normes de données.

AWS Types de catalogues de données Glue

Le catalogue de données est un metastore, un registre de tables et de champs stockés dans divers systèmes de données. Lorsque les composants AWS Glue, tels que les robots AWS Glue et les tâches AWS Glue with Spark, écrivent dans le catalogue de données, ils le font à l'aide d'un système de typage interne permettant de suivre les types de champs. Ces valeurs sont affichées dans la colonne Type de données du schéma de table de la console AWS Glue. Ce système de types est basé sur le système de types d'Apache Hive. Pour plus d'informations sur le système de types Apache Hive, veuillez consulter la rubrique [Types](#) du wiki Apache Hive. Pour plus d'informations sur les types spécifiques et leur support, des exemples sont fournis dans la console AWS Glue, dans le cadre du Schema Builder.

Validation, compatibilité et autres utilisations

Le catalogue de données ne valide pas les types écrits dans des champs de type. Lorsque les composants de AWS Glue lisent et écrivent dans le catalogue de données, ils sont compatibles entre eux. Les composants Glue visent également à préserver un haut degré de compatibilité avec les types Hive. Cependant, les composants AWS Glue ne garantissent pas la compatibilité avec tous les types de Hive. Cela permet l'interopérabilité avec des outils tels que les DDL Athena lorsque vous utilisez des tables dans le catalogue de données.

Le catalogue de données ne validant pas les types, d'autres services peuvent utiliser le catalogue de données pour suivre les types à l'aide de systèmes strictement conformes au système de types Hive ou à tout autre système.

Types dans les scripts AWS Glue with Spark

Lorsqu'un script AWS Glue with Spark interprète ou transforme un ensemble de données, nous fournissons `DynamicFrame` une représentation en mémoire de votre ensemble de données tel qu'il est utilisé dans votre script. L'objectif d'un `DynamicFrame` est similaire à celui du `DataFrame Spark` : il modélise votre jeu de données afin que Spark puisse planifier et exécuter des transformations sur vos données. Nous garantissons que la représentation du type de `DynamicFrame` est compatible avec un `DataFrame` en fournissant les méthodes `toDF` et `fromDF`.

Si les informations de type peuvent être déduites ou fournies à un `DataFrame`, elles peuvent être déduites ou fournies à un `DynamicFrame`, sauf indication contraire. Lorsque nous fournissons des lecteurs ou des rédacteurs optimisés pour des formats de données spécifiques, si Spark peut lire ou écrire vos données, les lecteurs et rédacteurs pourront le faire également, sous réserve de restrictions documentées. Pour plus d'informations sur les lecteurs et les rédacteurs, veuillez consulter la rubrique [the section called “Options de format de données”](#).

Le type de choix

Les `DynamicFrames` fournissent un mécanisme pour modéliser les champs d'un jeu de données dont les valeurs peuvent présenter des types incohérents sur le disque entre les lignes. Par exemple, un champ peut contenir un nombre stocké sous forme de chaîne dans certaines lignes et un entier dans d'autres. Ce mécanisme est un type en mémoire appelé `Choice`. Nous proposons des transformations, telles que la `ResolveChoice` méthode, pour résoudre les colonnes `Choice` en un type concret. AWS Glue ETL n'écrit pas le type `Choice` dans le catalogue de données dans le cours normal des opérations ; les types `Choice` n'existent que dans le contexte des modèles de `DynamicFrame` mémoire des ensembles de données. Pour un exemple d'utilisation du type de choix, veuillez consulter la rubrique [the section called “Exemple de préparation des données”](#).

AWS Types de Glue Crawler

Les crawlers visent à produire un schéma cohérent et utilisable pour votre ensemble de données, puis à le stocker dans Data Catalog pour l'utiliser dans d'autres composants de AWS Glue et Athena. Les crawlers traitent les types comme indiqué dans la section précédente du catalogue de données, [the section called “AWS Types de catalogues de données Glue”](#). Pour produire un type utilisable dans les scénarios de type « choix », où une colonne contient des valeurs de deux types ou plus, les Crawlers créeront un type `struct` qui modélise les types potentiels.

Démarrage avec AWS Glue

Les sections suivantes fournissent des informations sur la configuration AWS Glue. Toutes les sections de configuration ne sont pas nécessaires pour commencer à utiliser AWS Glue. Vous pouvez utiliser les instructions selon vos besoins pour configurer les autorisations IAM, le chiffrement et le DNS (si vous utilisez un environnement VPC pour accéder aux banques de données ou si vous utilisez des sessions interactives).

Rubriques

- [Vue d'ensemble de l'utilisation AWS Glue](#)
- [Configuration des autorisations IAM pour AWS Glue](#)
- [Configuration des profils AWS Glue d'utilisation](#)
- [Démarrage avec le plugin AWS Glue Data Catalog](#)
- [Configuration de l'accès réseau aux magasins de données](#)
- [Configuration du chiffrement dans AWS Glue](#)
- [Mise en place d'un réseau pour le développement de AWS Glue](#)

Vue d'ensemble de l'utilisation AWS Glue

Avec AWS Glue, vous stockez les métadonnées dans le AWS Glue Data Catalog. Vous utilisez ces métadonnées pour orchestrer des tâches ETL qui transforment des sources de données et chargent votre entrepôt de données ou votre lac de données. Les étapes suivantes décrivent le flux de travail général et certains des choix que vous effectuez lorsque vous travaillez avec AWS Glue.

Note

Vous pouvez suivre les étapes ci-dessous, ou créer un flux de travail qui exécute automatiquement les étapes 1 à 3. Pour de plus amples informations, veuillez consulter [the section called “Exécution d'activités ETL complexes à l'aide de plans et de flux de travail”](#).

1. Renseignez le AWS Glue Data Catalog avec les définitions des tables.

Dans la console, pour les magasins de données persistantes, vous pouvez ajouter un crawler pour remplir le AWS Glue Data Catalog. Vous pouvez lancer l'assistant Add crawler (Ajout d'un crawler)

à partir de la liste des tables ou de la liste des crawlers. Vous choisissez un ou plusieurs magasins de données auxquels votre crawler accèdera. Vous pouvez également créer un calendrier pour déterminer la fréquence d'exécution de votre crawler. Pour les flux de données, vous pouvez créer manuellement la définition de table et définir les propriétés de flux.

Si vous le souhaitez, vous pouvez fournir un classifieur personnalisé qui déduit le schéma de vos données. Vous pouvez créer des classifieurs personnalisés à l'aide d'un modèle grok. Cependant, AWS Glue fournit des classificateurs intégrés qui sont automatiquement utilisés par les robots d'exploration si un classificateur personnalisé ne reconnaît pas vos données. Lorsque vous définissez un crawler, vous n'avez pas besoin de sélectionner un classifieur. Pour plus d'informations sur les classificateurs dans AWS Glue, voir [Définition et gestion des classificateurs](#).

L'analyse de certains types de magasins de données nécessite une connexion qui fournit des informations de localisation et d'authentification. Le cas échéant, vous pouvez créer une connexion qui fournit ces informations requises dans AWS Glue console.

L'crawler lit votre magasin de données et crée des définitions de données et des tables nommées dans le AWS Glue Data Catalog. Ces tables sont organisées dans une base de données de votre choix. Vous pouvez également remplir le catalogue de données avec des tables créées manuellement. Avec cette méthode, vous fournissez le schéma et d'autres métadonnées pour créer des définitions de table dans le catalogue de données. Cette méthode pouvant être un peu fastidieuse et source d'erreurs, il est souvent préférable de faire créer les définitions de table par un crawler.

Pour plus d'informations sur le AWS Glue Data Catalog remplissage des définitions de tables, consultez [Création de tables](#).

2. Définissez une tâche qui décrit la transformation de données de la source vers la cible.

En général, pour créer une tâche, vous devez faire les choix suivants :

- Choisissez un tableau dans le tableau AWS Glue Data Catalog qui sera la source de la tâche. Votre tâche utilise cette définition de table pour accéder à votre source de données et interpréter le format de ces dernières.
- Choisissez une table ou un emplacement parmi ceux AWS Glue Data Catalog qui seront la cible de la tâche. Votre tâche utilise cette information pour accéder à votre magasin de données.
- Racontez AWS Glue pour générer un script permettant de transformer votre source en cible. AWS Glue génère le code permettant d'appeler des transformations intégrées afin de convertir les données de son schéma source au format de schéma cible. Ces transformations réalisent

des opérations comme copier des données, renommer des colonnes et filtrer des données pour transformer les données si nécessaire. Vous pouvez modifier ce script dans AWS Glue console.

Pour plus d'informations sur la définition des tâches dans AWS Glue, voir [Création de tâches ETL visuelles avec AWS Glue Studio](#).

3. Exécutez votre tâche pour transformer vos données.

Vous pouvez exécuter votre tâche à la demande, ou la démarrer en fonction d'un des types de déclencheurs suivants :

- Un déclencheur basé sur une planification cron.
- Un déclencheur basé sur un événement ; par exemple, la réussite d'une autre tâche peut démarrer une AWS Glue travail.
- Un déclencheur qui lance une tâche à la demande.

Pour plus d'informations sur les déclencheurs dans AWS Glue, voir [Démarrage des tâches et des crawlers à l'aide de déclencheurs](#).

4. Surveillez vos crawlers planifiés et vos tâches déclenchées.

Utilisez la commande AWS Glue console pour afficher les éléments suivants :

- Les détails et les erreurs de l'exécution d'une tâche.
- Les détails et les erreurs de l'exécution d'un crawler.
- Toutes les notifications concernant AWS Glue activités

Pour plus d'informations sur la surveillance de vos robots d'exploration et de vos jobs dans AWS Glue, voir [Surveillance AWS Glue](#).

Configuration des autorisations IAM pour AWS Glue

Les instructions de cette rubrique vous aident à configurer rapidement des autorisations AWS Identity and Access Management (IAM) pour AWS Glue. Vous réaliserez les tâches suivantes :

- Accordez à vos identités IAM l'accès aux AWS Glue ressources.
- Créez un rôle de service pour exécuter des tâches, accéder aux données et exécuter AWS Glue des tâches de qualité des données.

Pour obtenir des instructions détaillées que vous pouvez utiliser pour personnaliser les autorisations IAM AWS Glue, consultez [Configuration des autorisations IAM pour AWS Glue](#).

Pour configurer les autorisations IAM pour AWS Glue AWS Management Console

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez Mise en route.
3. Sous Préparer votre compte pour AWS Glue, choisissez Configurer les autorisations IAM.
4. Choisissez les identités IAM (rôles ou utilisateurs) auxquelles vous souhaitez accorder AWS Glue des autorisations. AWS Glue attache la politique [AWSGlueConsoleFullAccess](#) gérée à ces identités. Vous pouvez ignorer cette étape si vous souhaitez définir ces autorisations manuellement ou uniquement définir une fonction du service par défaut.
5. Choisissez Suivant.
6. Choisissez le niveau d'accès Amazon S3 dont vos rôles et utilisateurs ont besoin. Les options que vous choisissez à cette étape sont appliquées à toutes les identités que vous avez sélectionnées.
 - a. Sous Choisir les emplacements S3, choisissez les emplacements Amazon S3 auxquels vous souhaitez accorder l'accès.
 - b. Ensuite, indiquez si vos identités doivent avoir un accès en lecture seule (recommandé) ou en lecture et écriture aux emplacements que vous avez sélectionnés précédemment. AWS Glue ajoute des politiques d'autorisation à vos identités en fonction de la combinaison des emplacements et des autorisations de lecture ou d'écriture que vous sélectionnez.

Le tableau suivant indique les autorisations associées AWS Glue à l'accès à Amazon S3.

Si vous choisissez...	AWS Glue attache...
Pas de modification	Aucune autorisation. AWS Glue n'apportera aucune modification aux autorisations de votre identité.
Accorder l'accès à des emplacements Amazon S3 spécifiques (lecture seule)	La politique gérée par le client accorde l' <code>AWSGlueConsole-S3-read-only-policy</code> accès à des sites Amazon S3

Si vous choisissez...	AWS Glue attache...
	spécifiques avec des autorisations de lecture seule. <pre data-bbox="917 331 1507 1444">{ "Version": "2012-10-17", "Statement": [{ "Effect": "Allow", "Action": ["s3:GetObject"], "Resource": ["arn:aws:s3:::amzn-s3-demo-bucket1/*", "arn:aws:s3:::amzn-s3-demo-bucket2/*", "arn:aws:s3:::amzn-s3-demo-bucket3", "arn:aws:s3:::amzn-s3-demo-bucket"], "Condition": { "StringEquals": { "aws:ResourceAccount": "000000000000" } } }] }</pre>

Si vous choisissez...	AWS Glue attache...
Accorder l'accès à des emplacements Amazon S3 spécifiques (lecture et écriture)	AWSGlueConsole-S3-read-and-write-policy accorde l'accès à des emplacements Amazon S3 spécifiques avec des autorisations de lecture et d'écriture. <pre data-bbox="911 489 1511 1799"> { "Version": "2012-10-17", "Statement": [{ "Effect": "Allow", "Action": ["s3:GetObject", "s3:PutObject"], "Resource": ["arn:aws:s3:::aes-siem-000000000000-log/*", "arn:aws:s3:::aes-siem-000000000000-snapshot/*", "arn:aws:s3:::aes-siem-000000000000-log", "arn:aws:s3:::aes-siem-000000000000-snapshot"], "Condition": { "StringEquals": { "aws:ResourceAccount": "000000000000" } } }] }</pre>

7. Choisissez Suivant.

8. Choisissez un rôle AWS Glue de service par défaut pour votre compte. Un rôle de service est un rôle IAM qui AWS Glue permet d'accéder aux ressources d'autres AWS services en votre nom. Pour de plus amples informations, veuillez consulter [Fonctions du service pour AWS Glue](#).
- Lorsque vous choisissez le rôle de AWS Glue service standard, vous AWS Glue créez un nouveau rôle IAM dans votre Compte AWS nom `AWSGlueServiceRole` avec les politiques gérées suivantes jointes. Si votre compte possède déjà un rôle IAM nommé `AWSGlueServiceRole`, AWS Glue associe ces politiques au rôle existant.
 - [AWSGlueServiceRole](#)— Cette politique gérée est requise pour accéder AWS Glue aux ressources et les gérer en votre nom. Il permet AWS Glue de créer, de mettre à jour et de supprimer diverses ressources telles que des AWS Glue jobs, des crawlers et des connexions. Cette politique accorde également des autorisations pour accéder AWS Glue aux Amazon CloudWatch journaux à des fins de journalisation. Pour commencer, nous vous recommandons d'utiliser cette politique pour savoir comment l'utiliser AWS Glue. Au fur et à mesure que vous vous y AWS Glue habituez, vous pourrez créer des politiques qui vous permettront d'ajuster l'accès aux ressources selon vos besoins.
 - [AWSGlueConsoleFullAccess](#)— Cette politique gérée accorde un accès complet au AWS Glue service via le AWS Management Console. Cette politique accorde des autorisations pour effectuer n'importe quelle opération dans ce cadre AWS Glue, vous permettant de créer, de modifier et de supprimer n'importe quelle AWS Glue ressource selon vos besoins. Cependant, il est important de noter que cette politique n'accorde pas d'autorisations pour accéder aux magasins de données sous-jacents ou à d'autres AWS services susceptibles d'être impliqués dans le processus ETL. En raison de l'étendue des autorisations accordées par la `AWSGlueConsoleFullAccess` politique, celles-ci doivent être attribuées avec prudence et en respectant le principe du moindre privilège. Il est généralement recommandé de créer et d'utiliser des politiques plus détaillées adaptées à des cas d'utilisation et à des exigences spécifiques dans la mesure du possible.
 - [AWSGlueConsole-S3- read-only-policy](#) — Cette politique permet de lire des données AWS Glue à partir de compartiments Amazon S3 spécifiés, mais elle n'accorde pas l'autorisation d'écrire ou de modifier des données dans Amazon S3 ou
- [AWSGlueConsole-S3- read-and-write](#) — Cette politique permet de AWS Glue lire et d'écrire des données dans des compartiments Amazon S3 spécifiés dans le cadre du processus ETL.
- Lorsque vous choisissez un rôle IAM existant, AWS Glue définissez-le comme rôle par défaut, mais n'y ajoutez pas d'`AWSGlueServiceRole` autorisations. Assurez-vous d'avoir configuré le

rôle à utiliser en tant que rôle de service pour AWS Glue. Pour plus d'informations, consultez [Étape 1 : créer une politique IAM pour AWS Glue web](#) et [Étape 2 : créer un rôle IAM pour AWS Glue](#).

9. Choisissez Suivant.

10. Enfin, passez en revue les autorisations que vous avez sélectionnées, puis choisissez Appliquer les modifications. Lorsque vous appliquez les modifications, AWS Glue ajoute des autorisations IAM aux identités que vous avez sélectionnées. Vous pouvez consulter ou modifier les nouvelles autorisations dans la console IAM à <https://console.aws.amazon.com/iam/> l'adresse.

Vous avez maintenant terminé la configuration des autorisations IAM minimales pour AWS Glue. Dans un environnement de production, nous vous recommandons de vous familiariser avec les AWS ressources [Sécurité dans AWS Glue](#) adaptées [Gestion des identités et des accès pour AWS Glue](#) à votre cas d'utilisation et de vous aider à les sécuriser.

Étapes suivantes

Maintenant que les autorisations IAM sont configurées, vous pouvez explorer les rubriques suivantes pour commencer à utiliser AWS Glue :

- [Commencer avec AWS GlueAWS Skill Builder](#)
- [Démarrage avec le plugin AWS Glue Data Catalog](#)

Configuration pour AWS Glue Studio

Effectuez les tâches de cette section lorsque vous utilisez AWS Glue pour la première fois pour l'ETL visuel :

Rubriques

- [Passez en revue les autorisations IAM nécessaires pour AWS Glue Studio utilisateur](#)
- [Examinez les autorisations IAM nécessaires pour les tâches ETL](#)
- [Configurer les autorisations IAM pour AWS Glue Studio](#)
- [Configuration d'un VPC pour votre tâche ETL](#)

Passez en revue les autorisations IAM nécessaires pour AWS Glue Studio utilisateur

Pour utiliser AWS Glue Studio, l'utilisateur doit avoir accès à différentes AWS ressources. L'utilisateur doit être en mesure de consulter et de sélectionner les compartiments Amazon S3, les politiques et les rôles IAM, et AWS Glue Data Catalog objets.

AWS Glue autorisations de service

AWS Glue Studio utilise les actions et les ressources du AWS Glue service. Votre utilisateur a besoin d'autorisations sur ces actions et ressources pour les utiliser efficacement AWS Glue Studio. Vous pouvez accorder le AWS Glue Studio utilisez la politique `AWSGlueConsoleFullAccess` gérée ou créez une politique personnalisée avec un ensemble d'autorisations réduit.

Important

Conformément aux bonnes pratiques en matière de sécurité, il est recommandé de restreindre l'accès en limitant les politiques afin de réduire davantage l'accès au compartiment Amazon S3 et aux groupes de journaux Amazon CloudWatch . Pour obtenir un exemple de politique Amazon S3, consultez la rubrique [Writing IAM Policies: How to Grant Access to an Amazon S3 Bucket](#) (Rédaction de politiques IAM : comment accorder l'accès à un compartiment Amazon S3).

Création de politiques IAM personnalisées pour AWS Glue Studio

Vous pouvez créer une politique personnalisée avec un plus petit ensemble d'autorisations pour AWS Glue Studio. La politique peut accorder des autorisations pour un sous-ensemble d'objets ou d'actions. Utilisez les informations suivantes lors de la création d'une politique personnalisée.

Pour utiliser le plugin AWS Glue Studio APIs, incluez `glue:UseGlueStudio` dans la politique d'action vos autorisations IAM. L'utilisation vous `glue:UseGlueStudio` permettra d'accéder à tous AWS Glue Studio actions même si de nouvelles actions sont ajoutées à l'API au fil du temps.

Pour plus d'informations sur les actions définies par AWS Glue, voir [Actions définies par AWS Glue](#).

Préparation des données et création d'actions

- `SendRecipeAction`
- `GetRecipeAction`

Actions associées aux graphes orientés acycliques (DAG)

- CreateDag
- UpdateDag
- GetDag
- DeleteDag

Actions associées aux tâches

- SaveJob
- GetJob
- CreateJob
- DeleteJob
- GetJobs
- UpdateJob

Actions associées à l'exécution des tâches

- StartJobRun
- GetJobRuns
- BatchStopJobRun
- GetJobRun
- QueryJobRuns
- QueryJobs
- QueryJobRunsAggregated

Actions associées aux schémas

- GetSchema
- GetInferredSchema

Actions associées aux bases de données

- GetDatabases

Actions associées aux plans

- GetPlan

Actions associées aux tableaux

- SearchTables
- GetTables
- GetTable

Actions associées aux connexions

- CreateConnection
- DeleteConnection
- UpdateConnection
- GetConnections
- GetConnection

Actions associées au mappage

- GetMapping

Actions associées aux proxy S3

- ListBuckets
- ListObjectsV2
- GetBucketLocation

Actions associées aux configurations de sécurité

- GetSecurityConfigurations

Actions associées aux scripts

- CreateScript (différent de l'API du même nom dans AWS Glue)

Accès AWS Glue Studio APIs

Pour accéder AWS Glue Studio, ajoutez `glue:UseGlueStudio` la liste des politiques d'actions dans les autorisations IAM.

Dans l'exemple ci-dessous, `glue:UseGlueStudio` est inclus dans la politique d'action, mais le AWS Glue Studio APIs ne sont pas identifiés individuellement. En effet, lorsque vous incluez `glue:UseGlueStudio`, vous avez automatiquement accès à l'interne APIs sans avoir à spécifier l'individu AWS Glue Studio APIs dans les autorisations IAM.

Dans l'exemple, les politiques d'action supplémentaires répertoriées (par exemple, `glue:SearchTables`) ne sont pas AWS Glue Studio APIs, ils devront donc être inclus dans les autorisations IAM selon les besoins. Vous pouvez également inclure des actions de proxy Amazon S3 pour spécifier le niveau d'accès Amazon S3 à accorder. L'exemple de politique ci-dessous fournit l'accès à Open AWS Glue Studio, créez une tâche visuelle et enregistrez-la ou exécutez-la si le rôle IAM sélectionné dispose d'un accès suffisant.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "VisualEditor0",
      "Effect": "Allow",
      "Action": [
        "glue:UseGlueStudio",
        "iam:ListRoles",
        "iam:ListUsers",
        "iam:ListGroups",
        "iam:ListRolePolicies",
        "iam:GetRole",
        "iam:GetRolePolicy",
        "glue:SearchTables",
        "glue:GetConnections",
        "glue:GetJobs",
        "glue:GetTables",
        "glue:BatchStopJobRun",
        "glue:GetSecurityConfigurations",
        "glue>DeleteJob",
        "glue:GetDatabases",
        "glue>CreateConnection",
        "glue:GetSchema",
        "glue:GetTable",
```

```

        "glue:GetMapping",
        "glue:CreateJob",
        "glue:DeleteConnection",
        "glue:CreateScript",
        "glue:UpdateConnection",
        "glue:GetConnection",
        "glue:StartJobRun",
        "glue:GetJobRun",
        "glue:UpdateJob",
        "glue:GetPlan",
        "glue:GetJobRuns",
        "glue:GetTags",
        "glue:GetJob",
        "glue:QueryJobRuns",
        "glue:QueryJobs",
        "glue:QueryJobRunsAggregated",
        "glue:SendRecipeAction",
        "glue:GetRecipeAction"
    ],
    "Resource": "*"
},
{
    "Action": [
        "iam:PassRole"
    ],
    "Effect": "Allow",
    "Resource": "arn:aws:iam::*:role/AWSGlueServiceRole*",
    "Condition": {
        "StringLike": {
            "iam:PassedToService": [
                "glue.amazonaws.com"
            ]
        }
    }
}
]
}
}

```

Autorisations relative au bloc-notes et à la prévisualisation des données

Les prévisualisations de données et les blocs-notes vous autorisent à visualiser un échantillon de vos données à n'importe quelle étape de votre tâche (lecture, transformation, écriture), sans avoir à exécuter le travail. Vous spécifiez un rôle AWS Identity and Access Management (IAM) pour AWS Glue Studio à utiliser lors de l'accès aux données. Les rôles IAM sont prévus pour être assumables et ne disposent pas d'informations d'identification standard à long terme comme un mot de passe ou des clés d'accès associées. Au lieu de cela, lorsque AWS Glue Studio assume le rôle, IAM lui fournit des informations de sécurité temporaires.

Pour s'assurer que les prévisualisations de données et les commandes du bloc-notes fonctionnent correctement, utilisez un rôle dont le nom commence par la chaîne `AWSGlueServiceRole`. Si vous choisissez d'utiliser un nom différent pour votre rôle, vous devez alors ajouter l'autorisation `iam:passrole` et configurer une politique pour le rôle dans IAM. Pour de plus amples informations, veuillez consulter [Créez une politique IAM pour les rôles non nommés « AWSGlue ServiceRole * »](#).

Warning

Si un rôle accorde l'autorisation `iam:passrole` pour un bloc-notes et que vous mettez en œuvre le chaînage des rôles, un utilisateur pourrait accéder involontairement à ce bloc-notes. Actuellement, aucun système d'audit n'est mis en place pour vous permettre de contrôler les utilisateurs qui ont été autorisés à accéder au bloc-notes.

Si vous souhaitez refuser à une identité IAM la possibilité de créer des sessions d'aperçu des données, consultez l'exemple suivant [the section called “Refus de la possibilité de créer des sessions d'aperçu des données à une identité”](#).

Autorisations Amazon CloudWatch

Vous pouvez surveiller votre AWS Glue Studio emplois utilisant Amazon CloudWatch, qui collecte et traite les données brutes provenant de AWS Glue en near-real-time métriques lisibles. Par défaut, AWS Glue les données des métriques sont envoyées CloudWatch automatiquement. Pour plus d'informations, consultez [Qu'est-ce qu'Amazon CloudWatch ?](#) dans le guide de CloudWatch l'utilisateur Amazon, et [AWS Glue Les indicateurs](#) figurent dans le guide du AWS Glue développeur.

Pour accéder aux CloudWatch tableaux de bord, l'utilisateur accède à AWS Glue Studio nécessite l'un des éléments suivants :

- La politique `AdministratorAccess`

- La politique `CloudWatchFullAccess`
- Une politique personnalisée qui inclut une ou plusieurs de ces autorisations spécifiques :
 - `cloudwatch:GetDashboard` et `cloudwatch:ListDashboards` pour afficher les tableaux de bord
 - `cloudwatch:PutDashboard` pour pouvoir créer ou modifier des tableaux de bord
 - `cloudwatch:DeleteDashboards` pour supprimer des tableaux de bord

Pour plus d'informations sur la modification des autorisations pour un utilisateur IAM à l'aide de politiques, veuillez consulter la rubrique [Modification des autorisations pour un utilisateur IAM](#) dans le Guide de l'utilisateur IAM.

Examinez les autorisations IAM nécessaires pour les tâches ETL

Lorsque vous créez une tâche à l'aide de AWS Glue Studio, le travail suppose les autorisations du rôle IAM que vous spécifiez lors de sa création. Ce rôle IAM doit être autorisé à extraire des données de votre source de données, à écrire des données sur votre cible et à accéder aux AWS Glue ressources.

Le nom du rôle que vous créez pour la tâche doit commencer par la chaîne `AWSGlueServiceRole` pour qu'il soit utilisé correctement par AWS Glue Studio. Par exemple, vous pouvez donner un nom à votre rôle `AWSGlueServiceRole-FlightDataJob`.

Autorisations de source et de cible de données

Un AWS Glue Studio Le travail doit avoir accès à Amazon S3 pour toutes les sources, cibles, scripts et répertoires temporaires que vous utilisez dans le cadre de votre travail. Vous pouvez créer une politique pour fournir un accès détaillé à des ressources Amazon S3 spécifiques.

- Les sources de données nécessitent les autorisations `s3:ListBucket` et `s3:GetObject`.
- Les sources de données nécessitent les autorisations `s3:ListBucket`, `s3:PutObject` et `s3:DeleteObject`.

Note

Votre politique IAM doit autoriser `s3:GetObject` les compartiments spécifiques utilisés pour héberger AWS Glue des transformations.

Les compartiments suivants appartiennent au compte de AWS service et sont lisibles dans le monde entier. Ces compartiments servent de référentiel pour le code source correspondant à un sous-ensemble de transformations accessibles via l'éditeur AWS Glue Studio visuel. Les autorisations sur le compartiment sont configurées pour refuser toute autre action d'API sur le compartiment. Tout le monde peut lire les scripts que nous fournissons pour les transformations, mais personne en dehors de notre équipe de service ne peut y « mettre » quoi que ce soit. Lorsque votre AWS Glue tâche s'exécute, ce fichier est extrait sous forme d'importation locale afin qu'il soit téléchargé dans le conteneur local. Après cela, il n'y a plus de communication avec ce compte.

Région : nom du compartiment

- af-south-1 : -762339736633- aws-glue-studio-transforms -1 prod-af-south
- ap-east-1 : -125979764932- aws-glue-studio-transforms -1 prod-ap-east
- ap-northeast-2 : -673535381443- -2 aws-glue-studio-transforms prod-ap-northeast
- ap-northeast-3 : -149976050262- -3 aws-glue-studio-transforms prod-ap-northeast
- ap-south-1 : -584702181950- aws-glue-studio-transforms -1 prod-ap-south
- ap-south-2 : -380279651983- -2 aws-glue-studio-transforms prod-ap-south
- ap-southeast-1 : -737106620487- -1 aws-glue-studio-transforms prod-ap-southeast
- ap-southeast-2 : -234881715811- -2 aws-glue-studio-transforms prod-ap-southeast
- ap-southeast-3 : -151265630221- -3 aws-glue-studio-transforms prod-ap-southeast
- ap-southeast-4 : -052235663858- -4 aws-glue-studio-transforms prod-ap-southeast
- ca-central-1 : -622716468547- aws-glue-studio-transforms -1 prod-ca-central
- ca-west-1 : -915795495192- aws-glue-studio-transforms -1 prod-ca-west
- eu-central-1 : -560373232017- aws-glue-studio-transforms -1 prod-eu-central
- aws-glue-studio-transformseu-central-2 : -907358657121- -2 prod-eu-central
- eu-north-1 : -312557305497- -1 aws-glue-studio-transforms prod-eu-north
- eu-south-1 : -939684186351- -1 aws-glue-studio-transforms prod-eu-south
- eu-south-2 : -239737454084- -2 aws-glue-studio-transforms prod-eu-south
- eu-west-1 : aws-glue-studio-transforms -244479516193- -1 prod-eu-west
- eu-west-2 : aws-glue-studio-transforms -804222392271- -2 prod-eu-west
- eu-west-3 : aws-glue-studio-transforms -371299348807- -3 prod-eu-west

- aws-glue-studio-transformsil-central-1 : -806964611811- -1 prod-il-central
- me-central-1 : -733304270342- aws-glue-studio-transforms -1 prod-me-central
- me-south-1 : -112120182341- -1 aws-glue-studio-transforms prod-me-south
- sa-east-1 : -881619130292- aws-glue-studio-transforms -1 prod-sa-east
- us-east-1 : -510798373988- aws-glue-studio-transforms -1 prod-us-east
- aws-glue-studio-transformsus-east-2 : -251189692203- -2 prod-us-east
- us-west-1 : aws-glue-studio-transforms -593230150239- -1 prod-us-west
- us-west-2 : aws-glue-studio-transforms -818035625594- -2 prod-us-west
- ap-northeast-1 : -200493242866- -1 aws-glue-studio-transforms prod-ap-northeast
- cn-north-1 : aws-glue-studio-transforms -071033555442- -1 prod-cn-north
- cn-northwest-1 : -070947029561- -1 aws-glue-studio-transforms prod-cn-northwest
- us-gov-west-1 : aws-glue-studio-transforms -227493901923- -1-2604 prod-us-gov-west

Si vous le souhaitez Amazon Redshift comme source de données, vous pouvez attribuer un rôle aux autorisations de cluster. Les tâches exécutées sur un Amazon Redshift cluster émettent des commandes qui accèdent à Amazon S3 pour un stockage temporaire à l'aide d'informations d'identification temporaires. Si votre tâche s'exécute pendant plus d'une heure, ces informations d'identification expirent, ce qui entraîne l'échec de la tâche. Pour éviter ce problème, vous pouvez attribuer un rôle au cluster Amazon Redshift lui-même qui accorde les autorisations nécessaires aux tâches utilisant des informations d'identification temporaires. Pour de plus amples informations, veuillez consulter la rubrique [Déplacement de données vers et depuis Amazon Redshift](#) dans le Guide du développeur AWS Glue .

Si la tâche utilise des sources ou des cibles de données autres qu'Amazon S3, vous devez attacher les autorisations nécessaires au rôle IAM utilisé par la tâche pour accéder à ces sources et cibles de données. Pour de plus amples informations, veuillez consulter [Configuration de votre environnement pour accéder aux magasins de données](#) dans le Guide du développeur AWS Glue .

Si vous utilisez des connecteurs et des connexions pour votre magasin de données, vous avez besoin d'autorisations supplémentaires, comme décrit dans [the section called “Autorisations requises pour l'utilisation de connecteurs”](#).

Autorisations requises pour supprimer des tâches

Entrée AWS Glue Studio vous pouvez sélectionner plusieurs tâches à supprimer dans la console. Pour effectuer cette action, vous devez disposer de l'autorisation `glue:BatchDeleteJob`. Ceci

est différent du AWS Glue console, qui nécessite l'`glue:DeleteJob` autorisation de supprimer des tâches.

AWS Key Management Service autorisations

Si vous prévoyez d'accéder aux sources et aux cibles Amazon S3 qui utilisent le chiffrement côté serveur avec AWS Key Management Service (AWS KMS), associez une politique au AWS Glue Studio rôle utilisé par la tâche qui permet à la tâche de déchiffrer les données. Le rôle de la tâche nécessite les autorisations `kms:ReEncrypt`, `kms:GenerateDataKey` et `kms:DescribeKey`. En outre, le poste doit être `kms:Decrypt` autorisé à charger ou à télécharger un objet Amazon S3 chiffré à l'aide d'une clé principale AWS KMS du client (CMK).

L'utilisation entraîne des frais supplémentaires AWS KMS CMKs. Pour plus d'informations, consultez les sections [AWS Key Management Service Concepts - Customer Master Keys \(CMKs\)](#) et [AWS Key Management Service Tarification](#) dans le guide du AWS Key Management Service développeur.

Autorisations requises pour l'utilisation de connecteurs

Si vous utilisez un AWS Glue Connecteur personnalisé et connexion pour accéder à un magasin de données, rôle utilisé pour exécuter le AWS Glue La tâche ETL nécessite des autorisations supplémentaires :

- Politique gérée par `AWS AmazonEC2ContainerRegistryReadOnly` pour accéder aux connecteurs achetés auprès de AWS Marketplace.
- Les autorisations `glue:GetJob` et `glue:GetJobs`.
- AWS Secrets Manager autorisations d'accès aux secrets utilisés avec les connexions. Consultez [Example: Permission to retrieve secret values](#) (Exemple : Autorisation pour récupérer des valeurs secrètes) pour obtenir des exemples de politiques IAM.

Si vos recettes AWS Glue La tâche ETL s'exécute au sein d'un VPC exécutant Amazon VPC, puis le VPC doit être configuré comme décrit dans. [the section called "Configuration d'un VPC pour votre tâche ETL"](#)

Configurer les autorisations IAM pour AWS Glue Studio

Vous pouvez créer des rôles et affecter des politiques aux utilisateurs et aux rôles de tâches en recourant à l'utilisateur administrateur AWS .

Vous pouvez utiliser la politique `AWSGlueConsoleFullAccess` AWS gérée pour fournir les autorisations nécessaires à l'utilisation du AWS Glue Studio console.

Pour créer votre propre politique, suivez les étapes décrites dans [Créer une politique IAM pour le AWS Glue Service](#) décrit dans le guide du AWS Glue développeur. Incluez les autorisations IAM décrites précédemment dans [Passez en revue les autorisations IAM nécessaires pour AWS Glue Studio utilisateur](#).

Rubriques

- [Joignez des politiques au AWS Glue Studio utilisateur](#)
- [Créez une politique IAM pour les rôles non nommés « AWSGlue ServiceRole * »](#)

Joignez des politiques au AWS Glue Studio utilisateur

Tout AWS utilisateur qui se connecte au AWS Glue Studio la console doit être autorisée à accéder à des ressources spécifiques. Vous fournissez ces autorisations par le biais des politiques IAM attribuées à l'utilisateur.

Attachez la politique AWSGlueConsoleFullAccess gérée à l'utilisateur

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.
2. Dans le volet de navigation, choisissez Politiques.
3. Dans la liste des politiques, cochez la case à côté de AWSGlueConsoleFullAccess. Vous pouvez utiliser le menu Filtre et la zone de recherche pour filtrer la liste de politiques.
4. Sélectionnez Policy Actions (Actions de politique), puis sélectionnez Attach (Attacher).
5. Sélectionnez l'utilisateur auquel attacher la politique. Vous pouvez utiliser le menu Filtre et la zone de recherche pour filtrer la liste des entités du principal. Après avoir choisi l'utilisateur auquel attacher la politique, sélectionnez Attach policy (Attacher la politique).
6. Répétez les étapes précédentes pour attacher des politiques supplémentaires à l'utilisateur, selon vos besoins.

Créez une politique IAM pour les rôles non nommés « AWSGlue ServiceRole * »

Pour configurer une politique IAM pour les rôles utilisés par AWS Glue Studio

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.

2. Ajoutez une nouvelle politique IAM. Vous pouvez ajouter à une politique existante ou créer une nouvelle politique en ligne IAM. Pour créer une politique IAM :
 1. Sélectionnez Politiques (Politiques), puis Create Policy (Créer une politique). Si un bouton Get Started (Mise en route) est affiché, sélectionnez-le, puis sélectionnez Create Policy (Créer une politique).
 2. En regard de Create Your Own Policy (Créez votre politique), choisissez Select (Sélectionner).
 3. Dans le champ Nom de la politique, saisissez une valeur facile à mémoriser pour vous y reporter ultérieurement. Le cas échéant, entrez un texte descriptif dans Description.
 4. Dans le champ Policy Document (Document de la politique), saisissez une déclaration de politique au format suivant, puis sélectionnez Create Policy (Créer la politique) :
3. Copiez et collez les blocs suivants dans la politique sous le tableau « Statement », en les *my-interactive-session-role-prefix* remplaçant par le préfixe de tous les rôles courants pour lesquels les autorisations doivent être associées. AWS Glue

```
{
  "Action": [
    "iam:PassRole"
  ],
  "Effect": "Allow",
  "Resource": "arn:aws:iam::*:role/my-interactive-session-role-prefix",
  "Condition": {
    "StringLike": {
      "iam:PassedToService": [
        "glue.amazonaws.com "
      ]
    }
  }
}
```

Voici l'exemple complet avec les rangs Version et Déclaration inclus dans la politique

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Action": [
        "iam:PassRole"
      ]
    }
  ]
}
```

```
    ],
    "Effect": "Allow",
    "Resource": "arn:aws:iam::*:role/my-interactive-session-role-prefix",
    "Condition": {
      "StringLike": {
        "iam:PassedToService": [
          "glue.amazonaws.com "
        ]
      }
    }
  }
]
```

4. Pour activer la politique pour un utilisateur, choisissez Users (Utilisateurs).
5. Sélectionnez l'utilisateur auquel vous souhaitez attacher la stratégie.

Configuration d'un VPC pour votre tâche ETL

Vous pouvez utiliser Amazon Virtual Private Cloud (Amazon VPC) pour définir un réseau virtuel dans votre propre zone logiquement isolée au sein de ce que l' AWS Cloud on appelle un cloud privé virtuel (VPC). Vous pouvez lancer vos ressources AWS , comme des instances, dans votre VPC. Votre VPC ressemble beaucoup à un réseau traditionnel que vous pourriez exécuter dans votre propre centre de données, et présente l'avantage d'utiliser l'infrastructure évolutive d' AWS. Vous pouvez configurer votre VPC en sélectionnant sa plage d'adresses IP, en créant des sous-réseaux et en configurant des tables de routage, des passerelles réseau et des paramètres de sécurité. Vous pouvez connecter les instances de votre VPC à internet. Vous pouvez connecter votre VPC à votre propre centre de données d'entreprise, pour en faire AWS Cloud une extension de votre centre de données. Pour protéger les ressources dans chaque sous-réseau, vous pouvez utiliser plusieurs couches de sécurité, y compris des groupes de sécurité et des listes de contrôle d'accès réseau. Pour de plus amples informations, consultez le [Guide de l'utilisateur Amazon VPC](#).

Vous pouvez configurer votre AWS Glue Tâches ETL à exécuter au sein d'un VPC lors de l'utilisation de connecteurs. Vous devez configurer votre VPC pour les éléments suivants, selon vos besoins :

- Accès au réseau public pour les banques de données non incluses AWS. Tous les magasins de données auxquels la tâche peut accéder doivent être disponibles à partir du sous-réseau VPC.
- Si votre tâche a besoin d'accéder aux ressources du VPC et au réseau Internet public, le VPC doit disposer d'une passerelle de traduction d'adresses réseau (NAT) dans le VPC.

Pour de plus amples informations, veuillez consulter [Configuration de votre environnement pour accéder aux magasins de données](#) dans le Guide du développeur AWS Glue .

Commencer à utiliser les blocs-notes dans AWS Glue Studio

Lorsque vous démarrez un bloc-notes via AWS Glue Studio, toutes les étapes de configuration sont effectuées pour vous afin que vous puissiez explorer vos données et commencer à développer votre script de travail en quelques secondes seulement.

Les sections suivantes décrivent comment créer un rôle et octroyer les autorisations appropriées pour utiliser des blocs-notes dans AWS Glue Studio pour les tâches ETL.

Pour plus d'informations sur les actions définies par AWS Glue, voir [Actions définies par AWS Glue](#).

Rubriques

- [Octroi d'autorisations pour le rôle IAM](#)

Octroi d'autorisations pour le rôle IAM

Configuration AWS Glue Studio est une condition préalable à l'utilisation des ordinateurs portables.

Pour utiliser des blocs-notes dans AWS Glue, votre rôle nécessite les éléments suivants :

- Une relation de confiance avec AWS Glue pour l'action `sts:AssumeRole` et, si vous voulez le baliser, alors `sts:TagSession`.
- Une politique IAM contenant toutes les autorisations pour les blocs-notes, AWS Glue, et des sessions interactives.
- Une politique IAM pour un rôle de passe, car le rôle doit pouvoir se transmettre du bloc-notes aux séances interactives.

Par exemple, lorsque vous créez un nouveau rôle, vous pouvez ajouter une stratégie AWS gérée standard similaire `AWSGlueConsoleFullAccessRole` au rôle, puis ajouter une nouvelle stratégie pour les opérations du bloc-notes et une autre pour la `PassRole` stratégie IAM.

Actions nécessaires pour établir une relation de confiance avec AWS Glue

Lorsque vous démarrez une séance de bloc-notes, vous devez ajouter `sts:AssumeRole` à la relation d'approbation du rôle transmis au bloc-notes. Si votre séance inclut des identifications, vous

devez également transmettre l'action `sts:TagSession`. Sans ces actions, la séance de bloc-notes ne peut pas démarrer.

Par exemple :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

Politiques contenant des autorisations IAM pour les blocs-notes

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour les ordinateurs portables. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:StartNotebook",
        "glue:TerminateNotebook",
        "glue:GlueNotebookRefreshCredentials",
        "glue:DeregisterDataPreview",
        "glue:GetNotebookInstanceStatus",
        "glue:GlueNotebookAuthorize"
      ],
      "Resource": "*"
    }
  ]
}
```

Vous pouvez utiliser les politiques IAM suivantes pour autoriser l'accès à des ressources spécifiques :

- **AwsGlueSessionUserRestrictedNotebookServiceRole**: Fournit un accès complet à tous AWS Glue ressources sauf pour les sessions. Permet aux utilisateurs de créer et d'utiliser uniquement les séances de bloc-notes associées à l'utilisateur. Cette politique inclut également d'autres autorisations requises par AWS Glue pour gérer AWS Glue ressources dans d'autres AWS services.
- **AwsGlueSessionUserRestrictedNotebookPolicy**: fournit des autorisations qui permettent aux utilisateurs de créer et d'utiliser uniquement les sessions de bloc-notes associées à l'utilisateur. Cette politique inclut également des autorisations permettant explicitement aux utilisateurs de passer une restriction AWS Glue rôle de session.

Politique IAM pour transmettre un rôle

Lorsque vous créez un bloc-notes avec un rôle, ce rôle est ensuite transmis à des séances interactives afin que le même rôle puisse être utilisé aux deux endroits. En tant que tel, l'autorisation `iam:PassRole` doit faire partie de la politique du rôle.

Créez une politique pour votre rôle à l'aide de l'exemple suivant. Remplacez le numéro de compte par le vôtre et le nom du rôle.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "iam:PassRole",
      "Resource": "arn:aws:iam::0900000000210:role/<role_name>"
    }
  ]
}
```

Configuration des profils AWS Glue d'utilisation

L'un des principaux avantages de l'utilisation d'une plateforme cloud est sa flexibilité. Cependant, cette facilité de création de ressources informatiques risque de faire grimper les coûts du cloud

en l'absence de gestion et de garde-fous. Par conséquent, les administrateurs doivent trouver un équilibre entre éviter les coûts d'infrastructure élevés tout en permettant aux utilisateurs de travailler sans friction inutile.

Avec les profils AWS Glue d'utilisation, les administrateurs peuvent créer différents profils pour différentes catégories d'utilisateurs au sein du compte, telles que les développeurs, les testeurs et les équipes produit. Chaque profil est un ensemble unique de paramètres qui peuvent être attribués à différents types d'utilisateurs. Par exemple, les développeurs peuvent avoir besoin de plus de personnel et avoir un nombre maximum de travailleurs plus élevé, tandis que les équipes produit peuvent avoir besoin de moins de travailleurs et d'un délai d'expiration ou d'une valeur de délai d'inactivité plus faible.

Exemple de comportement des tâches et des exécutions de tâches


Supposons qu'une tâche soit créée par l'utilisateur A avec le profil A. La tâche est enregistrée avec certaines valeurs de paramètres. L'utilisateur B avec le profil B essaiera d'exécuter la tâche.

Lorsque l'utilisateur A a créé le travail, s'il n'a pas défini un nombre spécifique de travailleurs, le paramètre par défaut défini dans le profil de l'utilisateur A a été appliqué et enregistré avec les définitions du travail.

Lorsque l'utilisateur B exécute la tâche, elle s'exécute avec les valeurs enregistrées pour celle-ci. Si le profil de l'utilisateur B est plus restrictif et n'est pas autorisé à s'exécuter avec autant de travailleurs, l'exécution de la tâche échouera.

Profil d'utilisation en tant que ressource

Un profil AWS Glue d'utilisation est une ressource identifiée par un Amazon Resource Name (ARN). Tous les contrôles IAM (Identity and Access Management) par défaut s'appliquent, y compris les autorisations basées sur les actions et les ressources. Les administrateurs doivent mettre à jour la politique IAM des utilisateurs qui créent des AWS Glue ressources, en leur accordant l'accès à l'utilisation des profils.



Rubriques

- [Création et gestion de profils d'utilisation](#)
- [Profils d'utilisation et emplois](#)

Création et gestion de profils d'utilisation

Création d'un profil AWS Glue d'utilisation

Les administrateurs doivent créer des profils d'utilisation, puis les attribuer aux différents utilisateurs. Lorsque vous créez un profil d'utilisation, vous spécifiez des valeurs par défaut ainsi qu'une plage de valeurs autorisées pour différents paramètres de tâche et de session. Vous devez configurer au moins un paramètre pour les tâches ou les sessions interactives. Vous pouvez personnaliser la valeur par défaut à utiliser lorsqu'aucune valeur de paramètre n'est fournie pour la tâche, et/ou définir une limite de plage ou un ensemble de valeurs autorisées à des fins de validation si un utilisateur fournit une valeur de paramètre lors de l'utilisation de ce profil.

Les valeurs par défaut sont une bonne pratique définie par l'administrateur pour aider les auteurs de tâches. Lorsqu'un utilisateur crée une nouvelle tâche sans définir de valeur de délai d'expiration, le délai d'expiration par défaut du profil d'utilisation s'applique. Si l'auteur n'a pas de profil, les valeurs par défaut du AWS Glue service s'appliqueront et seront enregistrées dans la définition de la tâche. Lors de l' AWS Glue exécution, applique les limites définies dans le profil (min, max, travailleurs autorisés).

Une fois qu'un paramètre est configuré, tous les autres paramètres sont facultatifs. Les paramètres qui peuvent être personnalisés pour les tâches ou les sessions interactives sont les suivants :

- **Nombre de travailleurs** : limitez le nombre de travailleurs pour éviter une utilisation excessive des ressources informatiques. Vous pouvez définir une valeur par défaut, une valeur minimale et une valeur maximale. Le minimum est de 1.
- **Type de travailleur** : limitez les types de travailleurs adaptés à vos charges de travail. Vous pouvez définir un type par défaut et autoriser les types de travailleurs pour un profil utilisateur.
- **Délai d'expiration** : définissez la durée maximale pendant laquelle une tâche ou une session interactive peut s'exécuter et consommer des ressources avant son arrêt. Définissez des valeurs de délai d'expiration pour éviter les tâches de longue durée.

Vous pouvez définir une valeur par défaut, minimale et maximale en minutes. Le minimum est de 1 (minute). Bien que le délai d'expiration AWS Glue par défaut soit de 2880 minutes, vous pouvez définir n'importe quelle valeur par défaut dans le profil d'utilisation.

Il est recommandé de définir une valeur pour « par défaut ». Cette valeur sera utilisée pour la création de la tâche ou de la session si aucune valeur n'a été définie par l'utilisateur.

- **Délai d'inactivité** : définissez le nombre de minutes pendant lesquelles une session interactive est inactive avant l'expiration du délai après l'exécution d'une cellule. Définissez le délai d'inactivité pour que les sessions interactives se terminent une fois le travail terminé. La plage de temporisation d'inactivité doit être comprise dans la limite du délai d'expiration.

Vous pouvez définir une valeur par défaut, minimale et maximale en minutes. Le minimum est de 1 (minute). Bien que le délai d'expiration AWS Glue par défaut soit de 2880 minutes, vous pouvez définir n'importe quelle valeur par défaut dans le profil d'utilisation.

Il est recommandé de définir une valeur pour « par défaut ». Cette valeur sera utilisée pour la création de session si aucune valeur n'a été définie par l'utilisateur.

Pour créer un profil AWS Glue d'utilisation en tant qu'administrateur (console)

1. Dans le menu de navigation de gauche, choisissez Gestion des coûts.
2. Choisissez Créer un profil d'utilisation.
3. Entrez le nom du profil d'utilisation pour le profil d'utilisation.
4. Entrez une description facultative qui aidera les autres utilisateurs à reconnaître l'objectif du profil d'utilisation.

5. Définissez au moins un paramètre dans le profil. Tout champ du formulaire est un paramètre. Par exemple, le délai d'inactivité minimal de la session.
6. Définissez les balises facultatives qui s'appliquent au profil d'utilisation.
7. Choisissez Save (Enregistrer).

AWS Glue × Services Search [Option+S]

AWS Glue × [AWS Glue](#) > [Usage profiles](#) > Create usage profile

Create usage profile [Info](#)

When you create a usage profile, you can assign it to AWS IAM roles and users to control cloud costs.

Name and description

Usage profile name

Usage profile description - optional

Descriptions can be up to 2048 characters long.

Parameter configurations [Info](#)

⚠ Please configure at least one parameter for jobs or interactive sessions to create a usage profile. Once a parameter is configured, all other parameters are optional.

Customize parameter configurations for jobs

Number of workers

The number of workers of a defined worker_type that are allocated. Customize the number of workers to avoid excessive use of compute resources.

Default	Minimum	Maximum
10	1	20

Between minimum and maximum Minimum allowed value: 1

Worker type

The type of predefined worker that is allocated when a job runs. Select the relevant worker types for your workloads.

Default worker type

Allowed worker types

Timeout

The maximum time in minutes that an interactive session run can consume resources before it is terminated. Set up a timeout value to avoid long running sessions.

Default (minutes)	Minimum (minutes)	Maximum (minutes)
2880	1	4000

Between minimum and maximum Minimum allowed value: 1

Pour créer un profil d'utilisation (AWS CLI)

1. Entrez la commande suivante.

```
aws glue create-usage-profile --name profile-name --configuration file://  
config.json --tags list-of-tags
```

où le fichier config.json peut définir des valeurs de paramètres pour les sessions interactives (SessionConfiguration) et les jobs (JobConfiguration) :

```
//config.json (There is a separate blob for session/job configuration  
{  
  "SessionConfiguration": {  
    "timeout": {  
      "DefaultValue": "2880",  
      "MinValue": "100",  
      "MaxValue": "4000"  
    },  
    "idleTimeout": {  
      "DefaultValue": "30",  
      "MinValue": "10",  
      "MaxValue": "4000"  
    },  
    "workerType": {  
      "DefaultValue": "G.2X",  
      "AllowedValues": [  
        "G.2X",  
        "G.4X",  
        "G.8X"  
      ]  
    },  
    "numberOfWorkers": {  
      "DefaultValue": "10",  
      "MinValue": "1",  
      "MaxValue": "10"  
    }  
  },  
  "JobConfiguration": {  
    "timeout": {  
      "DefaultValue": "2880",  
      "MinValue": "100",  
      "MaxValue": "4000"
```

```
    },
    "workerType": {
      "DefaultValue": "G.2X",
      "AllowedValues": [
        "G.2X",
        "G.4X",
        "G.8X"
      ]
    },
    "numberOfWorkers": {
      "DefaultValue": "10",
      "MinValue": "1",
      "MaxValue": "10"
    }
  }
}
```

2. Entrez la commande suivante pour voir le profil d'utilisation créé :

```
aws glue get-usage-profile --name profile-name
```

La réponse :

```
{
  "ProfileName": "foo",
  "Configuration": {
    "SessionConfiguration": {
      "numberOfWorkers": {
        "DefaultValue": "10",
        "MinValue": "1",
        "MaxValue": "10"
      },
      "workerType": {
        "DefaultValue": "G.2X",
        "AllowedValues": [
          "G.2X",
          "G.4X",
          "G.8X"
        ]
      },
      "timeout": {
        "DefaultValue": "2880",
        "MinValue": "100",

```

```

        "MaxValue": "4000"
    },
    "idleTimeout": {
        "DefaultValue": "30",
        "MinValue": "10",
        "MaxValue": "4000"
    }
},
"JobConfiguration": {
    "numberOfWorkers": {
        "DefaultValue": "10",
        "MinValue": "1",
        "MaxValue": "10"
    },
    "workerType": {
        "DefaultValue": "G.2X",
        "AllowedValues": [
            "G.2X",
            "G.4X",
            "G.8X"
        ]
    },
    "timeout": {
        "DefaultValue": "2880",
        "MinValue": "100",
        "MaxValue": "4000"
    }
},
"CreatedOn": "2024-01-19T23:15:24.542000+00:00"
}

```

Commandes CLI supplémentaires utilisées pour gérer les profils d'utilisation :

- colle à cire list-usage-profiles
- aws glue update-usage-profile --name --configuration *profile-name* file://config.json
- aws glue delete-usage-profile --name *profile-name*

Modification d'un profil d'utilisation

Les administrateurs peuvent modifier les profils d'utilisation qu'ils ont créés afin de modifier les valeurs des paramètres de profil pour les tâches et les sessions interactives.

Pour modifier un profil d'utilisation :

Pour modifier un profil AWS Glue d'utilisation en tant qu'administrateur (console)

1. Dans le menu de navigation de gauche, choisissez Gestion des coûts.
2. Choisissez un profil d'utilisation que vous êtes autorisé à modifier, puis cliquez sur Modifier.
3. Apportez les modifications nécessaires au profil. Par défaut, les paramètres qui comportent déjà des valeurs sont développés.
4. Choisissez Enregistrer les modifications.

aws

Services

Search for services, features, blogs, docs, and more

[Alt+S]

N. Virginia

MyRole/AWSUser @ 0123-4567-8901

AWS Glue > Usage profiles > dev-profile-1 > Edit

Edit dev-profile-1

Name and description

Usage profile name

Usage profile description - optional

Write any details that will help you or others recognize the purpose of this configuration.

Descriptions can be up to 2048 characters long.

▼ Parameter configurations for jobs [Info](#)

Configure usage restrictions for AWS Glue jobs. Each parameter has a default value preconfigured for different types of jobs.

▼ Number of workers

The number of workers of a defined worker_type that are allocated. Customize number of workers to avoid excessive use of compute resources.

Default

Minimum

Maximum

Between minimum and maximum

Minimum allowed value: 1

▼ Worker type

The type of a unit capable of performing operational processes dictated by its fleet management system. Select the relevant worker types for your wo

Default worker type

G.2X

Clear selection

Allowed worker types

Choose one or more worker types

G.1X

G.2X

G.4X

G.8X

▶ Timeout

The maximum time in minutes that a job run can consume resources before it is terminated and. Setup timeout values to avoid long running jobs.

▼ Parmeter configurations for sessions [Info](#)

Configure usage restrictions for AWS Glue interactive sessions. Each parameter has a default value preconfigured for different types of interactive sessions.

▶ Number of workers

The number of workers of a defined worker_type that are allocated. Customize number of workers to avoid excessive use of compute resources.

▶ Worker type

The type of a unit capable of performing operational processes dictated by its fleet management system. Select the relevant worker types for your workloads.

▼ Idle timeout

The number of minutes of inactivity after which an interactive session will timeout after a cell has been executed. Define idle-timeout for sessions to terminate after the work completed.

Default (minutes)

Minimum (minutes)

Maximum (minutes)

Between minimum and maximum

Minimum allowed value: 1

▶ Timeout

The maximum time in minutes that an interactive session run can consume resources before it is terminated. Setup timeout values to avoid long running sessions.

▶ Tags – optional

Tags are user-defined key-value pairs that provide metadata to organize and classify your AWS resources.

Cancel

Save edits

CloudShell

Feedback

Language

© 2023, Amazon Web Services, Inc. or its affiliates.

Privacy

Terms

Cookie preferences

Gestion des profils d'utilisation

62

Pour modifier un profil d'utilisation (AWS CLI)

- Entrez la commande suivante. La même syntaxe de `--configuration` fichier est utilisée comme indiqué ci-dessus dans la commande de création.

```
aws glue update-usage-profile --name profile-name --configuration file://  
config.json
```

où le fichier `config.json` définit les valeurs des paramètres pour les sessions interactives (SessionConfiguration) et les jobs (JobConfiguration) :

Affectation d'un profil d'utilisation

La colonne État d'utilisation de la page Profils d'utilisation indique si un profil d'utilisation est attribué aux utilisateurs. Le survol de l'état indique les entités IAM assignées.

L'administrateur peut attribuer un profil d' AWS Glue utilisation aux utilisateurs/rôles qui créent AWS Glue des ressources. L'attribution d'un profil est une combinaison de deux actions :

- Mettre à jour le tag utilisateur/rôle IAM avec la `glue:UsageProfile` clé, puis
- Mise à jour de la politique IAM de l'utilisateur/du rôle.

Pour les utilisateurs qui utilisent AWS Glue Studio pour créer des tâches ou des sessions interactives, l'administrateur attribue les rôles suivants :

- Pour les restrictions sur les tâches, l'administrateur balise le rôle de console connecté
- Pour les restrictions sur les sessions interactives, l'administrateur balise le rôle fourni par l'utilisateur lors de la création du bloc-notes

Voici un exemple de politique que l'administrateur doit mettre à jour sur les utilisateurs/rôles IAM qui créent des ressources : AWS Glue

```
{  
  "Effect": "Allow",  
  "Action": [  
    "glue:GetUsageProfile"  
  ],  
  "Resource": [  

```

```
    "arn:aws:glue:us-east-1:123456789012:usageProfile/foo"  
  ]  
}
```

AWS Glue valide les demandes de travail, d'exécution de tâches et de session en fonction des valeurs spécifiées dans le profil AWS Glue d'utilisation et déclenche une exception si la demande est refusée. En mode synchrone APIs, une erreur sera renvoyée à l'utilisateur. Pour les chemins asynchrones, une exécution de tâche échouée est créée avec le message d'erreur indiquant que le paramètre d'entrée se situe en dehors de la plage autorisée pour le profil attribué à l'utilisateur/au rôle.

Pour attribuer un profil d'utilisation à un utilisateur/rôle :

1. Ouvrez la console IAM (Identity and Access Management).
2. Dans le volet de navigation de gauche, sélectionnez Utilisateurs ou Rôles.
3. Choisissez un utilisateur ou un rôle.
4. Sélectionnez l'onglet Tags (Identifications).
5. Choisissez Ajouter un nouveau tag
6. Ajoutez une balise avec la clé `glue:UsageProfile` et la valeur du nom de votre profil d'utilisation.
7. Choisissez Enregistrer les modifications

The screenshot shows the AWS IAM console interface for the `AWSGlueServiceRole` role. The breadcrumb navigation at the top indicates the path: `IAM > Roles > AWSGlueServiceRole`. The role name `AWSGlueServiceRole` is displayed with an `Info` link and a `Delete` button. Below this, a `Summary` section provides details: **Creation date** is June 28, 2023, 12:35 (UTC-07:00); **Last activity** is 27 days ago with a green checkmark icon; **ARN** is `arn:aws:iam:::role/service-role/AWSGlueServiceRole`; and **Maximum session duration** is 1 hour. An `Edit` button is located to the right of the summary. Below the summary, a horizontal tab bar includes `Permissions`, `Trust relationships`, `Tags (1)` (which is selected), `Access Advisor`, and `Revoke sessions`. The `Tags (1)` section shows a description: "Tags are key-value pairs that you can add to AWS resources to help identify, organize, or search for resources." and a `Manage tags` button. A table below lists the tag with the key `glue:UsageProfile` and the value `foo`.

Key	Value
glue:UsageProfile	foo

Afficher le profil d'utilisation qui vous a été attribué

Les utilisateurs peuvent consulter les profils d'utilisation qui leur sont assignés et les utiliser lorsqu'ils effectuent des appels d'API pour créer des ressources de AWS Glue tâche et de session, ou lorsqu'ils démarrent une tâche.

Les autorisations de profil sont fournies dans les politiques IAM. Tant que la politique d'appel prévoit `glue:UsageProfileautorisation`, un utilisateur peut voir le profil. Dans le cas contraire, vous recevrez un message d'erreur de refus d'accès.

Pour consulter un profil d'utilisation attribué, procédez comme suit :

1. Dans le menu de navigation de gauche, choisissez Gestion des coûts.
2. Choisissez un profil d'utilisation que vous êtes autorisé à consulter.

aws

Services

Search for services, service features, Marketplace products, docs, and more

?

?

?

N. Virginia

MyRole/AWSUser @ 0123-4567-8901

☑ Usage profile "dev-profile-1" successfully updated.

Usage profile "dev-profile-1" successfully updated. To assign it to IAM roles or users, go to AWS IAM service through the "Open AWS IAM" button and tag the IAM role or user with key: glue:UsageProfile and value: dev-profile-1.

Open AWS IAM

✕

?

AWS Glue > Usage profiles > dev-profile-1

dev-profile-1

EditDelete

Usage profile details

Usage profile name

dev-profile-1

Status

✔ Assigned

Created on

October 18, 2023, 14:32 (UTC+3:30)

Usage profile description

A long description of the flow. Long description of the flow. Long description of the flow. Long description of the flow. Long description of the flow.

Assigned IAM roles (8)

Find IAM roles

< 1 > ⚙

IAM role

AmazonSageMakerServiceCatalogProductsCloudformationRole

GlueRedshiftDevRole

GlueRedshiftTestRole

GlueRedshiftTestRole-2

GlueEMRRole

GlueEMRDevRole

GlueTestRole

GlueAppFlowRole

Assigned IAM users (100)

Find IAM users

< 1 2 3 ... > ⚙

IAM user

glue-dev-user-1

glue-dev-user-2

glue-dev-user-3

glue-test-user-1

glue-test-user-2

glue-test-user-3

glue-product-user-1

glue-product-user-1

Parameter configurations for jobs

Number of workers

Default

Minimum

Maximum

10

1

20

Worker type

Default type

Allowed types

G.2X

-

Timeout (minutes)

Default

Minimum

Maximum

2880

100

4000

Parameter configurations for sessions

Number of workers

Default

Minimum

Maximum

10

1

20

Worker type

Default type

Allowed types

G.1X

G.1X, G.4X, G.8X

Timeout (minutes)

Default

Minimum

Maximum

2880

100

4000

Idle timeout (minutes)

Default

Minimum

Maximum

30

10

200

Tags (3)

A tag is a label that you assign to an AWS resource. Each tag consists of a key and an optional value. You can use tags to search and filter your resources or track your AWS costs.

Find tags

< 1 > ⚙

Manage tags

Key

Value

Key-1

Value-1

Key-2

Value-2

Key-3

Value-3

Gestion des profils d'utilisation

66

Profils d'utilisation et emplois

Création de tâches à l'aide de profils d'utilisation

Lors de la création de tâches, les limites et les valeurs par défaut définies dans votre profil d'utilisation s'appliquent. Votre profil sera attribué au poste une fois enregistré.

Exécution de tâches avec des profils d'utilisation

Lorsque vous lancez une tâche, AWS Glue applique les limites définies dans le profil de votre appelant. S'il n'y a pas d'interlocuteur direct, Glue appliquera alors les limites du profil attribué au poste par son auteur.

Note

Lorsqu'une tâche est exécutée selon un calendrier (par des AWS Glue flux de travail ou des AWS Glue déclencheurs), le profil attribué à la tâche que l'auteur postule.

Lorsqu'une tâche est exécutée par un service externe (Step Functions, MWAA) ou une StartJobRun API, la limite de profil de l'appelant est appliquée.

Pour les AWS Glue flux de travail ou les AWS Glue déclencheurs : les tâches préexistantes doivent être mises à jour pour enregistrer le nouveau nom du profil afin que les limites du profil (nombre minimum, maximum et travailleurs autorisés) soient appliquées lors de l'exécution pour les exécutions planifiées.

Afficher un profil d'utilisation attribué à des tâches

Pour consulter le profil attribué à vos tâches (qui sera utilisé lors de l'exécution avec des AWS Glue flux de travail ou des AWS Glue déclencheurs planifiés), vous pouvez consulter l'onglet Détails de la tâche. Vous pouvez également consulter le profil utilisé lors des exécutions précédentes dans l'onglet Détails des exécutions de tâches.

Mettre à jour ou supprimer un profil d'utilisation associé à une tâche

Le profil attribué à une tâche est modifié lors de la mise à jour. Si aucun profil d'utilisation n'est attribué à l'auteur, tout profil précédemment associé à la tâche en sera supprimé.

Démarrage avec le plugin AWS Glue Data Catalog

AWS Glue Data Catalog Il s'agit de votre magasin de métadonnées techniques permanent. Il s'agit d'un service géré que vous pouvez utiliser pour stocker, annoter et partager des métadonnées dans le AWS cloud. Pour de plus amples informations, veuillez consulter [AWS Glue Data Catalog](#).

Le AWS Glue la console et certaines interfaces utilisateur ont été récemment mises à jour.

Présentation

Vous pouvez utiliser ce didacticiel pour créer votre premier AWS Glue Data Catalog, qui utilise un compartiment Amazon S3 comme source de données.

Dans ce didacticiel, vous allez effectuer les opérations suivantes à l'aide du AWS Glue console :

1. Créer une base de données
2. Créer une table
3. Utilisation d'un compartiment Amazon S3 comme source de données

Après avoir effectué ces étapes, vous aurez utilisé avec succès un compartiment Amazon S3 comme source de données pour remplir le AWS Glue Catalogue de données.

Étape 1 : Créer une base de données

Pour commencer, connectez-vous au AWS Management Console et ouvrez le [AWS Glue console](#).

Pour créer une base de données à l'aide du AWS Glue console :

1. Dans le volet AWS Glue console, choisissez Bases de données sous Catalogue de données dans le menu de gauche.
2. Choisissez Ajouter une base de données.
3. Sur la page Créer une base de données, saisissez un nom pour la base de données. Dans la section Emplacement – facultatif, définissez l'emplacement de l'URI à utiliser par les clients du catalogue de données. Si vous ne connaissez pas cette information, vous pouvez poursuivre la création de la base de données.
4. (Facultatif). Saisissez une description pour la base de données.

5. Choisissez Créer une base de données.

Félicitations, vous venez de configurer votre première base de données à l'aide du AWS Glue console. Votre nouvelle base de données apparaîtra dans la liste des bases de données disponibles. Vous pouvez modifier la base de données en choisissant le nom de la base de données dans le tableau de bord des Bases de données.

Étapes suivantes

Autres méthodes pour créer une base de données :

Vous venez de créer une base de données à l'aide du AWS Glue console, mais il existe d'autres moyens de créer une base de données :

- Vous pouvez utiliser des crawlers pour créer automatiquement une base de données et des tableaux pour vous. Pour configurer une base de données à l'aide de robots d'exploration, consultez la section [Utilisation des robots d'exploration dans le AWS Glue Console](#).
- Vous pouvez utiliser des AWS CloudFormation modèles. Voir [Création AWS Glue Ressources utilisant des AWS Glue Data Catalog modèles](#).
- Vous pouvez également créer une base de données à l'aide du AWS Glue Opérations d'API de base de données.

Pour créer une base de données à l'aide de l'opération `create`, structurez la demande en incluant les paramètres `DatabaseInput` (obligatoires).

Par exemple :

Voici des exemples illustrant comment utiliser l'interface de ligne de commande, Boto3 ou DDL pour définir un tableau basé sur le même fichier `flights_data.csv` à partir du compartiment S3 que vous avez utilisé dans le didacticiel.

CLI

```
aws glue create-database --database-input '{"Name":"clidb"}'
```

Boto3

```
glueClient = boto3.client('glue')
```

```
response = glueClient.create_database(  
    DatabaseInput={  
        'Name': 'boto3db'  
    }  
)
```

Pour en savoir plus sur les types de données, la structure et les opérations de l'API de base de données, consultez [API d'une base de données](#).

Étapes suivantes

Dans la section suivante, vous allez créer un tableau et l'ajouter à votre base de données.

Vous pouvez également consulter les paramètres et les autorisations de votre catalogue de données. Voir [Utilisation des paramètres du catalogue de données dans le AWS Glue Console](#).

Étape 2. Créer une table

Au cours de cette étape, vous allez créer un tableau à l'aide du AWS Glue console.

1. Dans le volet AWS Glue console, choisissez Tables dans le menu de gauche.
2. Choisissez Add table (Ajouter une table).
3. Configurez les propriétés de votre table en saisissant un nom pour votre table dans Table details (Détails de la table).
4. Dans la section Databases (Bases de données), choisissez la base de données que vous avez créée à l'étape 1 dans le menu déroulant.
5. Dans la section Add a data store (Ajouter un magasin de données), S3 sera sélectionné par défaut comme type de source.
6. Pour Data is located in (Les données se trouvent dans), choisissez Specified path in another account (Chemin d'accès spécifié dans un autre compte).
7. Copiez et collez le chemin pour le champ de saisie Include path (Chemin à inclure) :

```
s3://crawler-public-us-west-2/flight/2016/csv/
```

8. Dans la section Data format (Format de données), pour Classification (Catégorie), choisissez CSV et pour Delimiter (Délimiteur), choisissez comma (,) (Virgule (,)). Choisissez Suivant.

9. Il vous est demandé de définir un schéma. Un schéma définit la structure et le format d'un enregistrement de données. Choisissez Ajouter une colonne. Pour en savoir plus, consultez [Registre de schémas](#).
10. Spécifiez les propriétés de la colonne :
 - a. Entrez un nom de colonne.
 - b. Pour Type de colonne, « chaîne » est déjà sélectionnée par défaut.
 - c. Pour Numéro de colonne, « 1 » est déjà sélectionné par défaut.
 - d. Choisissez Ajouter.
11. Il vous est demandé d'ajouter des index de partition. Ce nom est facultatif. Pour sauter cette étape, choisissez Next (Suivant).
12. Une synthèse des propriétés du tableau s'affiche. Si tout se passe comme prévu, choisissez Create. Sinon, choisissez Back (Retour) et apportez les modifications nécessaires.

Félicitations, vous avez créé manuellement un tableau et l'avez associé à une base de données. Le tableau nouvellement créé apparaît dans le tableau de bord des tableaux. Dans le tableau de bord, vous pouvez gérer et modifier tous vos tableaux.

Pour plus d'informations, consultez la section [Utilisation des tables dans le AWS Glue Console](#).

Étapes suivantes

Étapes suivantes

Maintenant que le catalogue de données est rempli, vous pouvez commencer à créer des tâches dans AWS Glue. Voir [Création de jobs ETL visuels avec AWS Glue Studio](#).

Outre l'utilisation de la console, il existe d'autres moyens de définir des tableaux dans le catalogue de données, notamment :

- [Création et exécution d'un crawler](#)
- [Ajouter des classificateurs à un crawler dans AWS Glue](#)
- [En utilisant le AWS Glue API de tableau](#)
- [Utilisation du modèle AWS Glue Data Catalog](#)
- [Migrer un métastore Apache Hive](#).
- [Utilisation du AWS CLI](#) Boto3 ou du langage de définition de données (DDL)

Voici des exemples illustrant comment utiliser l'interface de ligne de commande, Boto3 ou DDL pour définir un tableau basé sur le même fichier `flights_data.csv` à partir du compartiment S3 que vous avez utilisé dans le didacticiel.

Consultez la documentation pour savoir comment structurer une AWS CLI commande. L'exemple de CLI contient la syntaxe JSON pour la valeur « `aws glue create-table --table-input` ».

CLI

```
{
  "Name": "flights_data_cli",
  "StorageDescriptor": {
    "Columns": [
      {
        "Name": "year",
        "Type": "bigint"
      },
      {
        "Name": "quarter",
        "Type": "bigint"
      }
    ],
    "Location": "s3://crawler-public-us-west-2/flight/2016/csv",
    "InputFormat": "org.apache.hadoop.mapred.TextInputFormat",
    "OutputFormat":
"org.apache.hadoop.hive ql.io.HiveIgnoreKeyTextOutputFormat",
    "Compressed": false,
    "NumberOfBuckets": -1,
    "SerdeInfo": {
      "SerializationLibrary":
"org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe",
      "Parameters": {
        "field.delim": ",",
        "serialization.format": ","
      }
    }
  },
  "PartitionKeys": [
    {
      "Name": "mon",
      "Type": "string"
    }
  ]
}
```

```
    }
  ],
  "TableType": "EXTERNAL_TABLE",
  "Parameters": {
    "EXTERNAL": "TRUE",
    "classification": "csv",
    "columnsOrdered": "true",
    "compressionType": "none",
    "delimiter": ",",
    "skip.header.line.count": "1",
    "typeOfData": "file"
  }
}
```

Boto3

```
import boto3

glue_client = boto3.client("glue")

response = glue_client.create_table(
    DatabaseName='sampledb',
    TableInput={
        'Name': 'flights_data_manual',
        'StorageDescriptor': {
            'Columns': [{
                'Name': 'year',
                'Type': 'bigint'
            }, {
                'Name': 'quarter',
                'Type': 'bigint'
            }],
            'Location': 's3://crawler-public-us-west-2/flight/2016/csv',
            'InputFormat': 'org.apache.hadoop.mapred.TextInputFormat',
            'OutputFormat':
                'org.apache.hadoop.hive.q1.io.HiveIgnoreKeyTextOutputFormat',
            'Compressed': False,
            'NumberOfBuckets': -1,
            'SerdeInfo': {
                'SerializationLibrary':
                    'org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe',
                'Parameters': {
```

```

        'field.delim': ',',
        'serialization.format': ',',
    }
},
'PartitionKeys': [{
    'Name': 'mon',
    'Type': 'string'
}],
'TableType': 'EXTERNAL_TABLE',
'Parameters': {
    'EXTERNAL': 'TRUE',
    'classification': 'csv',
    'columnsOrdered': 'true',
    'compressionType': 'none',
    'delimiter': ',',
    'skip.header.line.count': '1',
    'typeOfData': 'file'
}
}
)

```

DDL

```

CREATE EXTERNAL TABLE `sampledb`.`flights_data` (
  `year` bigint,
  `quarter` bigint)
PARTITIONED BY (
  `mon` string)
ROW FORMAT DELIMITED
  FIELDS TERMINATED BY ','
STORED AS INPUTFORMAT
  'org.apache.hadoop.mapred.TextInputFormat'
OUTPUTFORMAT
  'org.apache.hadoop.hive ql.io.HiveIgnoreKeyTextOutputFormat'
LOCATION
  's3://crawler-public-us-west-2/flight/2016/csv/'
TBLPROPERTIES (
  'classification'='csv',
  'columnsOrdered'='true',
  'compressionType'='none',
  'delimiter'=',',

```

```
'skip.header.line.count'='1',  
'typeOfData'='file')
```

Configuration de l'accès réseau aux magasins de données

Pour exécuter vos tâches d'extraction, de transformation et de chargement (ETL), AWS Glue doit être en mesure d'accéder à vos magasins de données. Si une tâche n'a pas besoin de s'exécuter dans le sous-réseau de votre Virtual Private Cloud (VPC), par exemple, si elle transforme les données d'Amazon S3 vers Amazon S3, aucune configuration supplémentaire n'est nécessaire.

Si une tâche a besoin de s'exécuter dans le sous-réseau de votre VPC, par exemple, si elle transforme les données d'un magasin de données JDBC dans un sous-réseau privé. AWS Glue met en place des [interfaces réseau élastiques](#) qui permettent à vos tâches de se connecter en toute sécurité aux autres ressources de votre VPC. À chaque interface réseau Elastic est affectée une adresse IP privée comprise dans la plage d'adresses IP du sous-réseau que vous avez spécifié. Aucune adresse IP publique n'est attribuée. Groupes de sécurité spécifiés dans le AWS Glue des connexions sont appliquées sur chacune des interfaces réseau élastiques. Pour de plus amples informations, veuillez consulter [Configuration d'Amazon VPC pour les connexions JDBC aux magasins de données Amazon RDS à partir de AWS Glue](#).

Tous les magasins de données JDBC auxquels la tâche peut accéder doivent être disponibles à partir du sous-réseau du VPC. Pour accéder à Amazon S3 à partir de votre VPC, un [point de terminaison d'un VPC](#) est requis. Si votre tâche a besoin d'accéder aux ressources du VPC et au réseau Internet public, le VPC doit disposer d'une passerelle de traduction d'adresses réseau (NAT) dans le VPC.

Une tâche ou un point de terminaison de développement ne peut accéder qu'à un seul VPC (et sous-réseau) à la fois. Si vous devez accéder aux banques de données de différentes manières VPCs, les options suivantes s'offrent à vous :

- Utilisez l'appairage de VPC pour accéder aux magasins de données. Pour plus d'informations sur l'appairage de VPC, consultez [Principes de base de l'appairage de VPC](#).
- Utilisez un compartiment Amazon S3 comme emplacement de stockage intermédiaire. Fractionnez le travail en deux tâches, avec la sortie Amazon S3 de la tâche 1 comme entrée de la tâche 2.

Pour plus d'informations sur la façon de se connecter à un magasin de données Amazon Redshift à l'aide d'Amazon VPC, consultez [the section called “Configurer Redshift”](#).

Pour plus d'informations sur la façon de se connecter aux magasins de données Amazon RDS à l'aide d'Amazon VPC, consultez [the section called “Configuration d'Amazon VPC pour se connecter aux magasins de données Amazon RDS”](#).

Une fois que les règles nécessaires sont définies dans Amazon VPC, vous créez une connexion dans AWS Glue avec les propriétés nécessaires pour se connecter à vos magasins de données. Pour plus d'informations sur la connexion, consultez [Connexion aux données](#).

 Note

Assurez-vous de configurer votre environnement DNS pour AWS Glue. Pour plus d'informations, consultez [Configuration du DNS de votre VPC](#).

Rubriques

- [Configuration d'un VPC pour se connecter à PyPI pour AWS Glue](#)
- [Configuration du DNS de votre VPC](#)

Configuration d'un VPC pour se connecter à PyPI pour AWS Glue

Le Python Package Index (PyPI) est un référentiel de logiciels pour le langage de programmation Python. Cette rubrique aborde les détails nécessaires pour prendre en charge l'utilisation des packages installés par pip (comme spécifié par le créateur de la session à l'aide de l'indicateur `--additional-python-modules`).

L'utilisation de sessions AWS Glue interactives avec un connecteur entraîne l'utilisation du réseau VPC via le sous-réseau spécifié pour le connecteur. Par conséquent, les AWS services et autres destinations réseau ne sont pas disponibles, sauf si vous configurez une configuration spéciale.

Les solutions à ce problème incluent :

- L'utilisation d'une passerelle Internet accessible par votre session.
- La configuration et l'utilisation d'un compartiment S3 avec un référentiel PyPI/simple contenant la fermeture transitive des dépendances d'un ensemble de packages.
- Utilisation d'un CodeArtifact référentiel qui met en miroir PyPI et qui est connecté à votre VPC.

Configuration d'une passerelle Internet

Les aspects techniques sont détaillés dans [Cas d'utilisation de la passerelle NAT](#), mais notez ces exigences pour l'utilisation de `--additional-python-modules`. Plus précisément, `--additional-python-modules` nécessite l'accès à `pypi.org`, qui est déterminé par la configuration de votre VPC. Notez les critères suivants :

1. L'obligation d'installer des modules Python supplémentaires via l'installation `pip` pour la session d'un utilisateur. Si la session utilise un connecteur, votre configuration peut être affectée.
2. Lorsqu'un connecteur est utilisé avec `--additional-python-modules`, lors du démarrage de la session, le sous-réseau associé aux `PhysicalConnectionRequirements` du connecteur doit fournir un chemin réseau pour atteindre `pypi.org`.
3. Vous devez déterminer si votre configuration est correcte ou non.

Configuration d'un compartiment Amazon S3 pour héberger un référentiel PyPI/simple ciblé

Cet exemple configure un miroir PyPI dans Amazon S3 pour un ensemble de packages et leurs dépendances.

Pour configurer le miroir PyPI pour un ensemble de packages :

```
# pip download all the dependencies
pip download -d s3pypi --only-binary :all: plotly ggplot
pip download -d s3pypi --platform manylinux_2_17_x86_64 --only-binary :all: psycpg2-binary
# create and upload the pypi/simple index and wheel files to the s3 bucket
s3pypi -b test-domain-name --put-root-index -v s3pypi/*
```

Si vous possédez déjà un référentiel d'artefacts, il contiendra une URL d'index pour l'utilisation de `pip` que vous pourrez fournir à la place de l'exemple d'URL pour le compartiment Amazon S3 comme indiqué ci-dessus.

Pour utiliser l'URL d'index personnalisée, avec quelques exemples de packages :

```
%%configure
{
    "--additional-python-modules": "psycpg2_binary==2.9.5",
```

```
"python-modules-installer-option": "--no-cache-dir --verbose --index-url https://test-domain-name.s3.amazonaws.com/ --trusted-host test-domain-name.s3.amazonaws.com"
}
```

Configuration d'un CodeArtifact miroir de pypi connecté à votre VPC

Pour configurer un miroir :

1. Créez un référentiel dans la même région que le sous-réseau utilisé par le connecteur.

Sélectionnez `Public upstream repositories` et choisissez `pypi-store`.

2. Fournissez un accès au référentiel depuis le VPC pour le sous-réseau.
3. Spécifiez l'`--index-url` correcte en utilisant le `python-modules-installer-option`.

```
%%configure
{
    "--additional-python-modules": "psycpg2_binary==2.9.5",
    "python-modules-installer-option": "--no-cache-dir --verbose --index-url https://test-domain-name.s3.amazonaws.com/ --trusted-host test-domain-name.s3.amazonaws.com"
}
```

Pour plus d'informations, consultez [Utiliser CodeArtifact depuis un VPC](#).

Configuration du DNS de votre VPC

Le DNS (Domain Name System) est une norme permettant la résolution des noms utilisés sur Internet en leurs adresses IP correspondantes. Un nom d'hôte DNS nomme de façon unique un ordinateur et se compose d'un nom d'hôte et d'un nom de domaine. Les serveurs DNS résolvent les noms d'hôte DNS en adresses IP correspondantes.

Pour configurer le DNS de votre VPC, assurez-vous que les noms d'hôte DNS et la résolution DNS sont activés dans votre VPC. Les attributs de réseau VPC `enableDnsHostnames` et `enableDnsSupport` doivent être définis sur `true`. Pour afficher et modifier ces attributs, accédez à la console VPC à l'adresse <https://console.aws.amazon.com/vpc/>.

Pour plus d'informations, consultez [Utilisation de DNS avec votre VPC](#). Vous pouvez également utiliser la [modify-vpc-attribute](#) commande AWS CLI and call pour configurer les attributs du réseau VPC.

 Note

Si vous utilisez Route 53, vérifiez que votre configuration ne remplace pas les attributs réseau DNS.

Configuration du chiffrement dans AWS Glue

L'exemple de flux de travail suivant met en évidence les options à configurer lorsque vous utilisez le chiffrement avec AWS Glue. L'exemple montre l'utilisation de touches spécifiques AWS Key Management Service (AWS KMS), mais vous pouvez choisir d'autres paramètres en fonction de vos besoins particuliers. Ce flux de travail met uniquement en évidence les options relatives au chiffrement lors de la configuration AWS Glue.

1. Si l'utilisateur du AWS Glue la console n'utilise pas de politique d'autorisation qui autorise tous AWS Glue Les opérations d'API (par exemple, "glue: *") confirment que les actions suivantes sont autorisées :
 - "glue:GetDataCatalogEncryptionSettings"
 - "glue:PutDataCatalogEncryptionSettings"
 - "glue:CreateSecurityConfiguration"
 - "glue:GetSecurityConfiguration"
 - "glue:GetSecurityConfigurations"
 - "glue>DeleteSecurityConfiguration"
2. Tout client qui accède ou écrit à un catalogue chiffré, c'est-à-dire, tout utilisateur de console, crawler, tâche ou point de terminaison de développement, nécessite les autorisations suivantes.

```
{
  "Version": "2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "kms:GenerateDataKey",
      "kms:Decrypt",
      "kms:Encrypt"
    ],
    "Resource": "<key-arns-used-for-data-catalog>"
  }
}
```

```
}
```

3. Tout utilisateur ou rôle qui accède à un mot de passe de connexion chiffré nécessite les autorisations suivantes.

```
{
  "Version": "2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "kms:Decrypt"
    ],
    "Resource": "<key-arns-used-for-password-encryption>"
  }
}
```

4. Le rôle de toute tâche Extract-transform-load (ETL) qui écrit des données chiffrées sur Amazon S3 a besoin des autorisations suivantes.

```
{
  "Version": "2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "kms:Decrypt",
      "kms:Encrypt",
      "kms:GenerateDataKey"
    ],
    "Resource": "<key-arns-used-for-s3>"
  }
}
```

5. Toute tâche ou robot d'exploration ETL qui écrit des Amazon CloudWatch Logs chiffrés nécessite les autorisations suivantes dans la clé et les politiques IAM.

Dans la stratégie de clé (et non la politique IAM) :

```
{
  "Effect": "Allow",
  "Principal": {
    "Service": "logs.region.amazonaws.com"
  },
  "Action": [
```

```

    "kms:Encrypt*",
    "kms:Decrypt*",
    "kms:ReEncrypt*",
    "kms:GenerateDataKey*",
    "kms:Describe*"
  ],
  "Resource": "<arn of key used for ETL/crawler cloudwatch encryption>"
}

```

Pour de plus amples informations sur les stratégies de clé, veuillez consulter la section [Utilisation de stratégies de clé dans AWS KMS](#) du Guide du développeur AWS Key Management Service .

Dans la politique IAM, attachez l'autorisation `logs:AssociateKmsKey` :

```

{
  "Effect": "Allow",
  "Principal": {
    "Service": "logs.region.amazonaws.com"
  },
  "Action": [
    "logs:AssociateKmsKey"
  ],
  "Resource": "<arn of key used for ETL/crawler cloudwatch encryption>"
}

```

6. Toute tâche ETL qui utilise un signet de tâche chiffré a besoin des autorisations suivantes.

```

{
  "Version": "2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "kms:Decrypt",
      "kms:Encrypt"
    ],
    "Resource": "<key-arns-used-for-job-bookmark-encryption>"
  }
}

```

7. Sur le AWS Glue console, choisissez Paramètres dans le volet de navigation.

- a. Sur la page Data catalog settings (Paramètres du catalogue de données), chiffrez votre catalogue de données en sélectionnant Metadata encryption (Chiffrement des métadonnées).

Cette option chiffre tous les objets du catalogue de données avec la AWS KMS clé de votre choix.

- b. Pour CléAWS KMS , choisissez aws/glue. Vous pouvez également choisir une AWS KMS clé que vous avez créée.

 Important

AWS Glue ne prend en charge que les clés principales symétriques du client (CMKs). La liste de AWS KMS key (clé KMS) n'affiche que des clés symétriques. Toutefois, si vous sélectionnez Choisir un ARN de AWS KMS clé, la console vous permet de saisir un ARN pour n'importe quel type de clé. Assurez-vous de n'entrer que ARNs pour les clés symétriques.

Lorsque le chiffrement est activé, le client qui accède au catalogue de données doit avoir les autorisations AWS KMS .

- 8. Dans le volet de navigation, choisissez Security configurations (Configurations de sécurité). Une configuration de sécurité est un ensemble de propriétés de sécurité qui peuvent être utilisées pour configurer AWS Glue processus. Ensuite, choisissez Ajouter une configuration de sécurité. Dans la configuration, choisissez l'une des options suivantes :
 - a. Sélectionnez S3 encryption (Chiffrement S3). Pour Mode de chiffrement, choisissez SSE-KMS. Pour la CléAWS KMS , choisissez aws/s3 (assurez-vous que l'utilisateur a l'autorisation d'utiliser cette clé). Cela permet aux données écrites par la tâche sur Amazon S3 d'utiliser AWS le AWS Glue AWS KMS clé.
 - b. Sélectionnez le chiffrement CloudWatch des journaux, puis choisissez une clé CMK. (Assurez-vous que l'utilisateur a l'autorisation d'utiliser cette clé). Pour plus d'informations, consultez la section [Chiffrer les données des CloudWatch journaux dans les journaux AWS KMSà l'aide](#) du guide du AWS Key Management Service développeur.

 Important

AWS Glue ne prend en charge que les clés principales symétriques du client (CMKs). La liste de AWS KMS key (clé KMS) n'affiche que des clés symétriques. Toutefois, si vous sélectionnez Choisir un ARN de AWS KMS clé, la console vous permet de saisir un ARN pour n'importe quel type de clé. Assurez-vous de n'entrer que ARNs pour les clés symétriques.

- c. Choisissez **Advanced properties (Propriétés avancées)** et sélectionnez **Job bookmark encryption (Chiffrement de signet de tâche)**. Pour la CléAWS KMS , choisissez **aws/glue** (assurez-vous que l'utilisateur a l'autorisation d'utiliser cette clé). Cela permet de chiffrer les signets de tâches écrits sur Amazon S3 à l'aide du AWS Glue AWS KMS clé.
9. Dans le volet de navigation, choisissez **Connections (Connexions)**.
- a. Choisissez **Ajouter une connexion** pour créer une connexion avec le magasin de données Java Database Connectivity (JDBC) qui est la cible de votre tâche ETL.
 - b. Pour appliquer le chiffrement Secure Sockets Layer (SSL), sélectionnez **Require SSL connection (Connexion SSL obligatoire)** et testez votre connexion.
10. Dans le volet de navigation, sélectionnez **Tâches**.
- a. Choisissez **Ajouter une tâche** pour créer une tâche qui transforme les données.
 - b. Dans la définition de tâche, choisissez la configuration de sécurité que vous avez créée.
11. Sur le AWS Glue console, exécutez votre travail à la demande. Vérifiez que toutes les données Amazon S3 écrites par la tâche, les CloudWatch journaux écrits par la tâche et les favoris de la tâche sont tous chiffrés.

Mise en place d'un réseau pour le développement de AWS Glue

Pour exécuter vos scripts d'extraction, de transformation et de chargement (ETL) avec AWS Glue, vous pouvez développer et tester vos scripts à l'aide d'un point de terminaison de développement. Les points de terminaison de développement ne sont pas pris en charge pour une utilisation avec AWS Glue jobs en version 2.0. Pour les versions 2.0 et ultérieures, la méthode de développement préférée consiste à utiliser Jupyter Notebook avec l'un des AWS Glue grains. Pour de plus amples informations, veuillez consulter [the section called “Démarrage avec AWS Glue sessions interactives”](#).

Configuration de votre réseau pour un point de terminaison de développement

Lorsque vous configurez un point de terminaison de développement, vous spécifiez un cloud privé virtuel (VPC), un sous-réseau et des groupes de sécurité.

Note

Assurez-vous de configurer votre environnement DNS pour AWS Glue. Pour plus d'informations, consultez [Configuration du DNS de votre VPC](#).

Pour activer AWS Glue pour accéder aux ressources requises, ajoutez une ligne dans la table de routage de votre sous-réseau afin d'associer une liste de préfixes pour Amazon S3 au point de terminaison VPC. Un ID de liste de préfixe est requis pour créer une règle de groupe de sécurité sortant qui autorise le trafic en provenance d'un VPC à accéder à un service AWS par le biais d'un point de terminaison d'un VPC. Pour faciliter la connexion à un serveur de bloc-notes associé à ce point de terminaison de développement, à partir de votre ordinateur local, ajoutez une ligne dans la table de routage pour ajouter un ID de passerelle Internet. Pour plus d'informations, consultez la page [Points de terminaison d'un VPC](#). Mettez à jour la table de routage du sous-réseau de sorte qu'elle soit similaire à la table suivante :

Destination	Cible		
10.0.0.0/16	locale		
pl-id pour Amazon S3	vpce-id		
0.0.0.0/0	igw-xxxx		

Pour activer AWS Glue pour communiquer entre ses composants, spécifiez un groupe de sécurité doté d'une règle d'autoréférencement entrant pour tous les ports TCP. En créant une règle avec référence circulaire, vous pouvez restreindre la source au même groupe de sécurité dans le VPC et ainsi, ne pas l'ouvrir à tous les réseaux. Le groupe de sécurité par défaut pour votre VPC peut déjà avoir une règle entrante avec référence circulaire pour ALL Traffic.

Pour configurer un groupe de sécurité

1. Connectez-vous à la EC2 console Amazon AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/ec2/>.
2. Dans le volet de navigation de gauche, sélectionnez Security Groups.
3. Sélectionnez un groupe de sécurité existant dans la liste, ou choisissez Create Security Group (Créer un groupe de sécurité) pour définir le groupe de sécurité à utiliser avec le point de terminaison de développement.
4. Dans le volet du groupe de sécurité, accédez à l'onglet Inbound (Entrant).
5. Ajoutez une règle d'autoréférencement pour autoriser AWS Glue composants pour communiquer. Plus spécifiquement, ajoutez ou confirmez qu'il existe une règle Type All TCP, que Protocol (Protocole) est TCP, que Port Range (Plage de ports) comprend tous les ports et

que la valeur de Source est le même nom de groupe de sécurité que la valeur de Group ID (ID du groupe).

La règle entrante ressemble à ce qui suit :

Type	Protocole	Plage de ports	Source
Tous les TCP	TCP	0-65535	<i>security-group</i>

L'exemple suivant présente une règle entrante avec référence circulaire :

Security Group: sg-19e1b768

Description Inbound Outbound Tags

Edit

Type ⓘ	Protocol ⓘ	Port Range ⓘ	Source ⓘ
SSH	TCP	22	0.0.0.0/0
HTTPS	TCP	443	0.0.0.0/0

- Ajoutez également une règle pour le trafic sortant. Ouvrez le trafic sortant pour tous les ports ou créez une règle avec référence circulaire de Type All TCP, de Protocole (Protocole) TCP, dont la valeur Port Range (Plage de ports) comprend tous les ports et que la valeur de Source est le même nom de groupe de sécurité que la valeur de Group ID (ID du groupe).

La règle sortante ressemble à l'une de ces règles :

Type	Protocole	Plage de ports	Destination
Tous les TCP	TCP	0-65535	<i>security-group</i>
Tout le trafic	ALL	ALL	0.0.0.0/0

Configuration d'Amazon EC2 pour un serveur d'ordinateurs portables

Un point de terminaison de développement permet de créer un serveur de bloc-notes pour tester vos scripts ETL avec les blocs-notes Jupyter. Pour activer la communication avec votre bloc-notes, spécifiez un groupe de sécurité avec des règles entrantes pour HTTPS (port 443) et SSH (port 22). Assurez-vous que la source de la règle est 0.0.0.0/0 ou l'adresse IP de la machine qui se connecte au bloc-notes.

Pour configurer un groupe de sécurité

1. Connectez-vous à la EC2 console Amazon AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/ec2/>.
2. Dans le volet de navigation de gauche, sélectionnez Security Groups.
3. Sélectionnez un groupe de sécurité existant dans la liste, ou choisissez Create Security Group (Créer un groupe de sécurité) pour définir le groupe de sécurité à utiliser avec votre serveur de bloc-notes. Le groupe de sécurité associé à votre point de terminaison de développement est également utilisé pour créer votre serveur de bloc-notes.
4. Dans le volet du groupe de sécurité, accédez à l'onglet Inbound (Entrant).
5. Ajoutez des règles entrantes semblables à ce qui suit :

Type	Protocole	Plage de ports	Source
SSH	TCP	22	0.0.0.0/0
HTTPS	TCP	443	0.0.0.0/0

L'image suivante présente un exemple de règles entrantes pour le groupe de sécurité :

Security Group: sg-19e1b768

- Description
- Inbound
- Outbound
- Tags

Edit

Type ⓘ	Protocol ⓘ	Port Range ⓘ	Source ⓘ
SSH	TCP	22	0.0.0.0/0
HTTPS	TCP	443	0.0.0.0/0

Découverte et catalogage des données dans AWS Glue

AWS Glue Data Catalog Il s'agit d'un référentiel centralisé qui stocke les métadonnées relatives aux ensembles de données de votre organisation. Il agit comme un index de l'emplacement, du schéma et des mesures d'exécution de vos sources de données. Les métadonnées sont stockées dans des tables de métadonnées, où chaque table représente un magasin de données unique.

Vous pouvez remplir le catalogue de données à l'aide d'un robot d'exploration, qui analyse automatiquement vos sources de données et extrait les métadonnées. Un robot d'exploration peut se connecter à des sources de données internes (AWS basées) et externes à AWS.

Pour plus d'informations sur les sources de données prises en charge, voir [Sources de données prises en charge pour l'exploration](#)

Vous pouvez également créer des tables manuellement dans le catalogue de données en définissant la structure des tables, le schéma et la structure de partitionnement en fonction de vos besoins spécifiques.

Pour plus d'informations sur la création manuelle de tables de métadonnées, consultez [Définition manuelle des métadonnées](#).

Vous pouvez utiliser les informations du catalogue de données pour créer et surveiller vos tâches ETL. Le catalogue de données s'intègre à d'autres services d'AWS analyse, fournissant une vue unifiée des sources de données, ce qui facilite la gestion et l'analyse des données.

- Amazon Athena — Stockez et interrogez les métadonnées des tables dans le catalogue de données pour les données Amazon S3 à l'aide de SQL.
- AWS Lake Formation — Définissez et gérez de manière centralisée des politiques d'accès aux données précises et auditez l'accès aux données.
- Amazon EMR — Accédez aux sources de données définies dans le catalogue de données pour le traitement des mégadonnées.
- Amazon SageMaker AI — Créez, formez et déployez des modèles d'apprentissage automatique rapidement et en toute confiance.

Principales fonctionnalités du catalogue de données

Les principaux aspects du catalogue de données sont les suivants.

Référentiel de métadonnées

Le catalogue de données agit comme un référentiel de métadonnées central, stockant des informations sur l'emplacement, le schéma et les propriétés de vos sources de données. Ces métadonnées sont organisées en bases de données et en tables, comme dans un catalogue de base de données relationnelle traditionnel.

Découverte automatique des données

AWS Glue crawler s peut automatiquement découvrir et cataloguer des sources de données nouvelles ou mises à jour, réduisant ainsi la charge de travail liée à la gestion manuelle des métadonnées et garantissant la pérennité de votre catalogue de données up-to-date. En cataloguant vos sources de données, le catalogue de données permet aux utilisateurs et aux applications de découvrir et de comprendre plus facilement les actifs de données disponibles au sein de votre organisation, favorisant ainsi la réutilisation des données et la collaboration.

Le catalogue de données prend en charge un large éventail de sources de données, notamment Amazon S3, Amazon RDS, Amazon Redshift, Apache Hive, etc. Il peut automatiquement déduire et stocker les métadonnées de ces sources à l'aide de AWS Glue crawler s.

Pour plus d'informations, voir, [Utilisation de robots d'exploration pour alimenter le catalogue de données](#).

Gestion des schémas

Le catalogue de données capture et gère automatiquement le schéma de vos sources de données, y compris l'inférence, l'évolution et le versionnement des schémas. Vous pouvez mettre à jour votre schéma et vos partitions dans le catalogue de données à l'aide de tâches AWS Glue ETL.

Optimisation des tables

Pour améliorer les performances de lecture des services AWS d'analyse tels qu'Amazon Athena et Amazon EMR, ainsi que pour les tâches AWS Glue ETL, le catalogue de données fournit un compactage géré (un processus qui compacte de petits objets Amazon S3 en objets plus grands) pour les tables Iceberg du catalogue de données. Vous pouvez utiliser une AWS Glue console, une AWS Lake Formation console ou une AWS API pour activer ou désactiver le compactage de tables Iceberg individuelles figurant dans le catalogue de données. AWS CLI

Pour de plus amples informations, veuillez consulter [Optimisation des tables Iceberg](#).

Statistiques de colonne

Vous pouvez calculer des statistiques au niveau des colonnes pour les tables du catalogue de données dans des formats de données tels que Parquet, ORC, JSON, ION, CSV et XML sans configurer de pipelines de données supplémentaires. Les statistiques de colonne vous aident à comprendre les profils de données en obtenant des informations sur les valeurs d'une colonne. Le catalogue de données permet de générer des statistiques pour les valeurs de colonne telles que la valeur minimale, la valeur maximale, le total des valeurs nulles, le total des valeurs distinctes, la longueur moyenne des valeurs et le nombre total d'occurrences de valeurs vraies.

Pour de plus amples informations, veuillez consulter [Optimisation des performances des requêtes à l'aide des statistiques des colonnes](#).

Lignage des données

Le catalogue de données conserve un enregistrement des transformations et des opérations effectuées sur vos données, fournissant des informations sur le lignage des données. Ces informations de traçabilité sont précieuses pour l'audit, la conformité et la compréhension de la provenance des données.

Intégration avec d'autres AWS services

Le catalogue de données s'intègre parfaitement à d'autres AWS services AWS Lake Formation, tels qu'Amazon Athena, Amazon Redshift Spectrum et Amazon EMR. Cette intégration vous permet d'interroger et d'analyser des données dans différents magasins de données à l'aide d'une couche de métadonnées unique et cohérente.

Sécurité et contrôle d'accès

AWS Glue s'intègre AWS Lake Formation pour prendre en charge un contrôle d'accès précis aux ressources du catalogue de données, ce qui vous permet de gérer les autorisations et de sécuriser l'accès à vos actifs de données en fonction des politiques et des exigences de votre organisation. AWS Glue s'intègre à AWS Key Management Service (AWS KMS) pour chiffrer les métadonnées stockées dans le catalogue de données.

Rubriques

- [Remplissage du catalogue de AWS Glue données](#)
- [Remplissage et gestion des tables transactionnelles](#)
- [Gestion du catalogue de données](#)

- [Accès au catalogue de données](#)
- [AWS Glue Bonnes pratiques en matière de catalogue de données](#)
- [Surveillance des métriques d'utilisation du catalogue de données dans Amazon CloudWatch](#)
- [AWS Glue Registre de schémas](#)

Remplissage du catalogue de AWS Glue données

Vous pouvez remplir le fichier à l' AWS Glue Data Catalog aide des méthodes suivantes :

- **AWS Glue crawler** — An AWS Glue crawler peut automatiquement découvrir et cataloguer des sources de données telles que des bases de données, des lacs de données et des données de streaming. Les robots d'exploration constituent la méthode la plus courante et la plus recommandée pour remplir le catalogue de données, car ils peuvent automatiquement découvrir et déduire les métadonnées d'une grande variété de sources de données.
- **Ajout manuel de métadonnées** : vous pouvez définir manuellement les bases de données, les tables et les détails de connexion et les ajouter au catalogue de données à l'aide de la AWS Glue console, de la console Lake Formation ou AWS Glue APIs. AWS CLI La saisie manuelle est utile lorsque vous souhaitez cataloguer des sources de données qui ne peuvent pas être explorées.
- **Intégration à d'autres AWS services** : vous pouvez remplir le catalogue de données avec des métadonnées provenant de services tels qu'Amazon AWS Lake Formation Athena. Ces services peuvent découvrir et enregistrer des sources de données dans le catalogue de données.
- **Remplissage à partir d'un référentiel de métadonnées existant** : si vous disposez d'un magasin de métadonnées existant tel qu'Apache Hive Metastore, vous pouvez l'utiliser AWS Glue pour importer ces métadonnées dans le catalogue de données. Pour plus d'informations, consultez la section [Migration entre le métastore Hive et le on. AWS Glue Data Catalog GitHub](#)

Rubriques


- [Utilisation de robots d'exploration pour alimenter le catalogue de données](#)
- [Définition manuelle des métadonnées](#)
- [Intégration à d'autres AWS services](#)
- [Paramètres du catalogue de données](#)

Utilisation de robots d'exploration pour alimenter le catalogue de données

Vous pouvez utiliser un AWS Glue crawler pour les renseigner AWS Glue Data Catalog avec des bases de données et des tables. Il s'agit de la principale méthode utilisée par la plupart des AWS Glue utilisateurs. Un crawler peut analyser plusieurs magasins de données en une seule fois. À la fin de cette opération, le crawler crée ou met à jour une ou plusieurs tables dans votre Data Catalog. Extrayez, transformez et chargez (ETL) les tâches que vous définissez dans AWS Glue utilisez ces tables du catalogue de données comme sources et cibles. La tâche ETL lit et écrit dans les magasins de données qui sont spécifiés dans les tables Data Catalog sources et cibles.

Flux de travail

Le schéma de flux de travail suivant montre comment AWS Glue les robots interagissent avec les magasins de données et d'autres éléments pour alimenter le catalogue de données.



Voici comment un crawler remplit le AWS Glue Data Catalog :

1. Un crawler exécute tous les classifieurs personnalisés que vous choisissez pour déduire le format et le schéma de vos données. Vous fournissez le code pour les classifieurs personnalisés, lesquels s'exécutent dans l'ordre que vous spécifiez.

Le premier classifieur personnalisé qui reconnaît avec succès la structure de vos données est utilisé pour créer un schéma. Les classifieurs personnalisés en bas de la liste sont ignorés.

2. Si aucun classifieur ne correspond au schéma de vos données, les classifieurs intégrés essaient de reconnaître le schéma de données. Un exemple de classifieur intégré est un classifieur qui reconnaît JSON.
3. L'crawler se connecte au magasin de données. Certains magasins de données nécessitent les propriétés de connexion pour l'accès de l'crawler.
4. Le schéma déduit est créé pour vos données.
5. L'crawler écrit les métadonnées dans le catalogue de données. Une définition de table contient les métadonnées sur les données de votre magasin de données. La table est écrite dans une base de données, qui est un conteneur de tables du catalogue de données. Les attributs d'une table incluent la classification, qui est une étiquette créée par le classifieur ayant déduit du schéma de la table.

Rubriques

- [Fonctionnement des crawlers](#)
- [Comment un crawler détermine quand créer des partitions ?](#)
- [Sources de données prises en charge pour l'exploration](#)
- [Prérequis pour le crawler](#)
- [Définition et gestion des classificateurs](#)
- [Configuration d'un crawler](#)
- [Planification d'un crawler](#)
- [Affichage des résultats et des détails du crawler](#)
- [Personnalisation du comportement des robots d'exploration](#)
- [Tutoriel : Ajouter un AWS Glue chenille](#)

Fonctionnement des crawlers

Lorsqu'un crawler s'exécute, il prend les actions suivantes pour interroger un magasin de données :

- Classe les données pour déterminer le format, le schéma et les propriétés associées des données brutes – Vous pouvez configurer les résultats de la classification en créant un classifieur personnalisé.
- Groupes les données en tables ou en partitions – Les données sont regroupées en fonction de l'heuristique de l'crawler.
- Writes metadata to the Data Catalog (Écrit les métadonnées sur Data Catalog) – vous pouvez configurer la façon dont l'crawler ajoute, met à jour et supprime les tables et les partitions.

Lorsque vous définissez un crawler, vous choisissez un ou plusieurs classifieurs qui évaluent le format de vos données pour déduire un schéma. Lorsque l'crawler s'exécute, le premier classifieur de la liste qui reconnaît correctement votre magasin de données est utilisé pour créer un schéma pour votre table. Vous pouvez utiliser des classifieurs intégrés ou définir les vôtres. Vous définissez vos classificateurs personnalisés lors d'une opération distincte, avant de définir les robots d'exploration. AWS Glue fournit des classificateurs intégrés pour déduire des schémas à partir de fichiers courants aux formats tels que JSON, CSV et Apache Avro. Pour la liste actuelle des classificateurs intégrés dans AWS Glue, voir [Classificateurs intégrés](#).

Les tables de métadonnées créées par un crawler sont contenues dans une base de données lorsque vous définissez un crawler. Si votre crawler ne spécifie pas de base de données, vos tables sont placées dans la base de données par défaut. En outre, chaque table dispose d'une colonne de classification remplie par le premier classifieur qui reconnaît correctement le magasin de données.

Si le fichier analysé est compressé, l'crawler doit le télécharger afin de le traiter. Lorsqu'un crawler s'exécute, il interroge les fichiers pour déterminer leur format et leur type de compression, et écrit ces propriétés dans Data Catalog. Certains formats de fichier (Apache Parquet, par exemple), vous permettent de compresser des parties du fichier au moment de son écriture. Pour ces fichiers, les données compressées constituent un composant interne du fichier, et AWS Glue ne renseigne pas la `compressionType` propriété lorsqu'il écrit des tables dans le catalogue de données. En revanche, si un fichier complet est compressé par un algorithme de compression (par exemple, gzip), la propriété `compressionType` est alors renseignée lorsque les tables sont écrites dans Data Catalog.

L'crawler génère les noms pour les tables qu'il crée. Les noms des tables stockées dans le sont conformes aux AWS Glue Data Catalog règles suivantes :


- Seuls les caractères alphanumériques et les traits de soulignement (_) sont autorisés.
- Un préfixe personnalisé ne doit pas comporter plus de 64 caractères.
- La longueur maximale du nom ne doit pas dépasser 128 caractères. L'crawler tronque les noms générés pour les ajuster à la limite.
- En cas de noms de table en double, l'crawler ajoute un suffixe de chaîne de hachage au nom.

Si votre crawler s'exécute plusieurs fois, par exemple sur un calendrier, il recherche les tables et les fichiers nouveaux ou modifiés dans votre magasin de données. La sortie de l'crawler inclut les nouvelles tables et partitions trouvées depuis l'exécution précédente.

Comment un crawler détermine quand créer des partitions ?

Quand un AWS Glue le crawler analyse la banque de données Amazon S3 et détecte plusieurs dossiers dans un compartiment, détermine la racine d'une table dans la structure des dossiers et quels dossiers sont des partitions d'une table. Le nom de la table est basé sur le préfixe Amazon S3 ou le nom de dossier. Vous fournissez un chemin Include qui pointe vers le niveau de dossier à analyser. Lorsque la majorité des schémas au niveau d'un dossier sont similaires, l'crawler crée les partitions d'une table au lieu de tables distinctes. Pour influencer l'crawler et créer des tables distincts, ajoutez le dossier racine de chaque table en tant que magasin de données séparé lorsque vous définissez l'crawler.

Prenons l'exemple de la structure de dossiers Amazon S3 suivante.



Les chemins d'accès aux quatre dossiers de niveau inférieur sont les suivants :

```
S3://sales/year=2019/month=Jan/day=1
```

```
S3://sales/year=2019/month=Jan/day=2
S3://sales/year=2019/month=Feb/day=1
S3://sales/year=2019/month=Feb/day=2
```

Supposons que la cible de l'crawler est définie sur Sales et que tous les fichiers des dossiers `day=n` ont le même format (par exemple, JSON, non chiffré) et ont des schémas identiques ou très similaires. L'crawler créera une seule table avec quatre partitions, avec les clés de partition `year`, `month` et `day`.

Dans l'exemple suivant, observez la structure Amazon S3 suivante :

```
s3://bucket01/folder1/table1/partition1/file.txt
s3://bucket01/folder1/table1/partition2/file.txt
s3://bucket01/folder1/table1/partition3/file.txt
s3://bucket01/folder1/table2/partition4/file.txt
s3://bucket01/folder1/table2/partition5/file.txt
```

Si les schémas pour les fichiers sous `table1` et `table2` sont similaires, et qu'un seul magasin de données est défini dans l'crawler avec `Include path s3://bucket01/folder1/`, l'crawler crée une seule table avec deux colonnes de clés de partition. La première colonne de clé de partition contient `table1` et `table2`, et la deuxième colonne de clé de partition contient `partition1` à `partition3` pour la partition `table1`, et `partition4` et `partition5` pour la partition `table2`. Pour créer deux tables distinctes, définissez l'crawler avec deux magasins de données. Dans cet exemple, définissez le premier `Include path` comme `s3://bucket01/folder1/table1/` et le second comme `s3://bucket01/folder1/table2`.

Note

Dans Amazon Athena, chaque table correspond à un préfixe Amazon S3 avec tous les objets qu'il contient. Si les objets ont des schémas différents, Athena ne reconnaît pas les différents objets au sein du même préfixe comme des tables distinctes. Cela peut se produire si un crawler crée plusieurs tables à partir du même préfixe Amazon S3. Il peut en résulter que des requêtes dans Athena ne renvoient aucun résultat. Pour qu'Athena reconnaisse et interroge correctement les tables, créez l'crawler avec un `Include path` (chemin d'inclusion) distinct pour chaque schéma de table différent dans la structure de dossier Amazon S3. Pour plus d'informations, consultez [Bonnes pratiques lors de l'utilisation d'Athena avec AWS Glue](#) et cet [article du centre de AWS connaissances](#).

Sources de données prises en charge pour l'exploration

Des crawlers peuvent analyser les magasins de données basés sur les fichiers et sur les tables suivants.

Type d'accès utilisé par l'crawler	Magasins de données
Client en mode natif	• Amazon Simple Storage Service (Amazon S3) • Amazon DynamoDB • Delta Lake 2.0.x • Apache Iceberg 1.5 • Apache Hudi 0.14
JDBC	Amazon Redshift Snowflake Dans Amazon Relational Database Service (Amazon RDS) ou externe à Amazon RDS : • Amazon Aurora • MariaDB • Microsoft SQL Server • MySQL • Oracle • PostgreSQL
Client MongoDB	• MongoDB • Atlas MongoDB • Amazon DocumentDB (compatible avec MongoDB)

 Note

Actuellement AWS Glue ne prend pas en charge les robots d'exploration pour les flux de données.

Pour les magasins de données JDBC, MongoDB, MongoDB Atlas et Amazon DocumentDB (compatibles avec MongoDB), vous devez spécifier un AWS Glue connexion que le robot d'exploration peut utiliser pour se connecter au magasin de données. Pour Amazon S3, vous pouvez éventuellement spécifier une connexion de type Network (Réseau). Une connexion est un objet Data Catalog qui stocke les informations de connexion, telles que les informations d'identification, l'URL, les informations de Virtual Private Cloud Amazon, etc. Pour de plus amples informations, veuillez consulter [Connexion aux données](#).

Les versions des pilotes prises en charge par le robot d'exploration sont les suivantes :

Produit (langue française non garantie)	Pilote compatible avec Crawler
PostgreSQL	42.2.1
Amazon Aurora	Identique aux pilotes de crawler natifs
MariaDB	8.0.13
Microsoft SQL Server	6.1.0
MySQL	8.0.13
Oracle	11.2.2
Amazon Redshift	4.1
Snowflake	3,13,20
MongoDB	4.7.2
Atlas MongoDB	4.7.2

Voici quelques remarques sur les différents magasins de données.

Amazon S3

Vous pouvez choisir d'explorer un chemin dans votre compte ou dans un autre compte. Si tous les fichiers Amazon S3 d'un dossier ont le même schéma, l'crawler crée une table. De plus, si l'objet Amazon S3 est partitionné, une seule table de métadonnées est créée et les informations de partition sont ajoutées à Data Catalog pour cette table.

Amazon S3 et Amazon DynamoDB

Les robots d'exploration utilisent un rôle AWS Identity and Access Management (IAM) pour obtenir l'autorisation d'accéder à vos magasins de données. Le rôle que vous transmettez à l'crawler doit avoir l'autorisation d'accéder aux chemins Amazon S3 et aux tables Amazon DynamoDB analysés.

Amazon DynamoDB

Lors de la définition d'un crawler à l'aide du AWS Glue console, vous spécifiez une table DynamoDB. Si vous utilisez le AWS Glue API, vous pouvez spécifier une liste de tables. Vous pouvez choisir d'analyser un petit échantillon des données uniquement pour réduire les temps d'exécution de l'crawler.

Delta Lake

Pour chaque magasin de données Delta Lake, vous précisez comment créer les tables Delta :

- Créer des tables natives : permettre l'intégration avec les moteurs de requêtes qui prennent directement en charge l'interrogation du journal de transactions Delta. Pour plus d'informations, veuillez consulter la rubrique [Interrogation des tables Delta Lake](#).
- Créer des tables avec des liens symboliques : créer un dossier `_symlink_manifest` avec les fichiers manifestes partitionnés par les clés de partition, en fonction des paramètres de configuration spécifiés.

Iceberg

Pour chaque magasin de données Iceberg, vous spécifiez un chemin Amazon S3 qui contient les métadonnées de vos tables Iceberg. Si le Crawler découvre des métadonnées de table Iceberg, il les enregistre dans le catalogue de données. Vous pouvez définir un calendrier pour que le Crawler mette à jour les tables.

Vous pouvez définir les paramètres suivants pour le magasin de données :

- Exclusions : permet d'ignorer certains dossiers.

- Profondeur maximale d'indexation : définit la limite de profondeur que le Crawler peut indexer dans votre compartiment Amazon S3. La profondeur maximale d'indexation par défaut est de 10 et la profondeur maximale que vous pouvez définir est de 20.

Hudi

Pour chaque magasin de données Hudi, vous spécifiez un chemin Amazon S3 qui contient les métadonnées de vos tables Hudi. Si le Crawler découvre des métadonnées de table Hudi, il les enregistre dans le catalogue de données. Vous pouvez définir un calendrier pour que le Crawler mette à jour les tables.

Vous pouvez définir les paramètres suivants pour le magasin de données :

- Exclusions : permet d'ignorer certains dossiers.
- Profondeur maximale d'indexation : définit la limite de profondeur que le Crawler peut indexer dans votre compartiment Amazon S3. La profondeur maximale d'indexation par défaut est de 10 et la profondeur maximale que vous pouvez définir est de 20.

Note

Les colonnes d'horodatage avec `millis` en tant que types logiques seront interprétées comme `bigint`, en raison d'une incompatibilité avec Hudi 0.13.1 et les types d'horodatage. Une solution pourrait être fournie dans la prochaine version de Hudi.

Les tables Hudi sont classées comme suit, avec des implications spécifiques pour chacune d'entre elles :

- Copie sur écriture (CoW) : les données sont stockées dans un format en colonnes (Parquet) et chaque mise à jour crée une version des fichiers lors d'une écriture.
- Fusion sur lecture (MoR) : les données sont stockées à l'aide d'une combinaison des formats en colonnes (Parquet) et basés sur les lignes (Avro). Les mises à jour sont consignées dans des fichiers delta basés sur les lignes et sont compressées si nécessaire pour créer de nouvelles versions des fichiers en colonnes.

Avec les ensembles de données CoW, chaque fois qu'une mise à jour est apportée à un enregistrement, le fichier qui contient l'enregistrement est réécrit avec les valeurs mises à jour. Avec un jeu de données MoR, chaque fois qu'une mise à jour a lieu, Hudi écrit uniquement la ligne du registre modifié. Le type de stockage MoR est mieux adapté aux charges de travail

donnant lieu à de nombreuses écritures ou modifications avec moins de lectures. Le type de stockage CoW est mieux adapté aux charges de travail lourdes en lecture sur des données qui changent moins fréquemment.

Hudi propose trois types de requêtes pour accéder aux données :

- Requetes d'instantané : requêtes qui affichent le dernier instantané de la table à partir d'une action de validation ou de compactage donnée. Pour les tables MoR, les requêtes d'instantané exposent l'état le plus récent de la table en fusionnant les fichiers de base et delta de la dernière tranche de fichiers au moment de la requête.
- Requetes progressives : les requêtes ne portent que sur les nouvelles données écrites dans la table, depuis une validation/un compactage donné. Cela fournit efficacement des flux de modifications pour activer les pipelines de données (Data Pipelines) progressives.
- Requetes à lecture optimisée : pour les tables MoR, les requêtes portent sur les dernières données compactées. Pour les tables CoW, les requêtes portent sur les dernières données validées.

Pour Copy-On-Write les tables, les robots créent une seule table dans le catalogue de données avec le `ReadOptimized org.apache.hudi.hadoop.HoodieParquetInputFormat` serde.

Pour Merge-On-Read les tables, le robot crée deux tables dans le catalogue de données pour le même emplacement de table :

- Une table avec un suffixe `_ro` qui utilise le `ReadOptimized org.apache.hudi.hadoop.HoodieParquetInputFormat` serde.
- Une table avec suffixe `_rt` qui utilise le `RealTime Serde` pour permettre les requêtes Snapshot :
`org.apache.hudi.hadoop.realtime.HoodieParquetRealtimeInputFormat`

MongoDB and Amazon DocumentDB (compatible avec MongoDB)

Les versions 3.2 et ultérieures de MongoDB sont prises en charge. Vous pouvez choisir d'analyser un petit échantillon des données uniquement pour réduire les temps d'exécution de l'crawler.

Base de données relationnelle

L'authentification est effectuée à l'aide d'un nom d'utilisateur et d'un mot de passe de base de données. En fonction du type de moteur de base de données, vous pouvez choisir quels objets sont analysés, comme les bases de données, les schémas et les tables.

Snowflake

Le crawler JDBC Snowflake prend en charge l'analyse de la table, de la table externe, de la vue et de la vue matérialisée. La définition de la vue matérialisée n'est pas renseignée.

Pour les tables externes Snowflake, le crawler n'effectue l'analyse que s'il pointe vers un emplacement Amazon S3. Outre le schéma de la table, le crawler analyse également l'emplacement, le format de fichier et la sortie d'Amazon S3 sous forme de paramètres de table dans la table du catalogue de données. Notez que les informations de partition de la table externe partitionnée ne sont pas renseignées.

Actuellement, ETL n'est pas pris en charge pour les tables du catalogue de données créées à l'aide du crawler Snowflake.

Prérequis pour le crawler

Le robot d'exploration assume les autorisations du rôle AWS Identity and Access Management (IAM) que vous spécifiez lorsque vous le définissez. Ce rôle IAM doit disposer d'autorisations pour extraire les données de votre magasin de données et écrire sur Data Catalog. Le AWS Glue la console répertorie uniquement les rôles IAM associés à une politique de confiance pour AWS Glue service principal. Dans la console, vous pouvez également créer un rôle IAM avec une politique IAM permettant d'accéder aux magasins de données Amazon S3 auxquels l'crawler accède. Pour plus d'informations sur la fourniture de rôles pour AWS Glue, voir [Politiques basées sur l'identité pour Glue AWS](#).

Note

Lorsque vous analysez un magasin de données Delta Lake, vous devez disposer d'autorisations en lecture/écriture sur l'emplacement Amazon S3.

Pour votre crawler, vous pouvez créer un rôle et attacher les politiques suivantes :

- La politique `AWSGlueServiceRole` AWS gérée, qui accorde les autorisations requises sur le catalogue de données
- Politique en ligne qui accorde des autorisations sur la source de données.
- Une politique intégrée qui accorde l'`iam:PassRole` autorisation d'utiliser le rôle.

Une approche plus rapide consiste à laisser AWS Glue l'assistant d'exploration de la console créer un rôle pour vous. Le rôle qu'il crée est spécifiquement destiné au robot d'exploration et inclut la politique `AWSGlueServiceRole` AWS gérée ainsi que la politique en ligne requise pour la source de données spécifiée.

Si vous spécifiez un rôle existant pour un crawler, assurez-vous qu'il inclut la politique `AWSGlueServiceRole` ou l'équivalent (ou une version limitée de cette politique), ainsi que les politiques en ligne requises. Par exemple, pour un magasin de données Amazon S3, la politique en ligne serait au minimum la suivante :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ],
      "Resource": [
        "arn:aws:s3:::bucket/object*"
      ]
    }
  ]
}
```

Pour un magasin de données Amazon DynamoDB, la politique serait au minimum la suivante :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "dynamodb:DescribeTable",
        "dynamodb:Scan"
      ],
      "Resource": [
        "arn:aws:dynamodb:region:account-id:table/table-name*"
      ]
    }
  ]
}
```

```
}
```

En outre, si le robot lit AWS Key Management Service (AWS KMS) des données Amazon S3 chiffrées, le rôle IAM doit disposer d'une autorisation de déchiffrement sur la clé. AWS KMS Pour de plus amples informations, veuillez consulter [Étape 2 : créer un rôle IAM pour AWS Glue](#).

Définition et gestion des classificateurs

Un classifieur lit les données d'un magasin de données. S'il reconnaît le format des données, il génère un schéma. Le classifieur renvoie également un pourcentage de certitude pour indiquer jusqu'à quel degré la reconnaissance du format était certaine.

AWS Glue fournit un ensemble de classificateurs intégrés, mais vous pouvez également créer des classificateurs personnalisés. AWS Glue invoque d'abord les classificateurs personnalisés, dans l'ordre que vous spécifiez dans la définition de votre robot d'exploration. En fonction des résultats renvoyés par les classificateurs personnalisés, AWS Glue peut également invoquer des classificateurs intégrés. Si un classificateur revient `certainty=1.0` pendant le traitement, cela indique qu'il est certain à 100 % qu'il peut créer le schéma correct. AWS Glue utilise ensuite la sortie de ce classificateur.

Si aucun classificateur ne revient `certainty=1.0`, AWS Glue utilise la sortie du classificateur qui présente la plus grande certitude. Si aucun classificateur ne renvoie une certitude supérieure `0.0` à, AWS Glue renvoie la chaîne de classification par défaut de `UNKNOWN`.

Quand dois-je utiliser un classifieur ?

Vous utilisez les classifieurs lorsque vous analysez un magasin de données pour définir les tables de métadonnées dans l' AWS Glue Data Catalog. Vous pouvez configurer votre crawler avec un ensemble ordonné de classifieurs. Lorsque le crawler appelle un classifieur, le classifieur détermine si les données sont reconnues. Si le classificateur ne peut pas reconnaître les données ou n'est pas certain à 100 %, le crawler appelle le prochain classificateur de la liste pour déterminer s'il peut reconnaître les données.

Pour plus d'informations sur la création d'un classificateur à l'aide du AWS Glue console, voir [Création de classificateurs à l'aide du AWS Glue console](#).

Classifieurs personnalisés

La sortie d'un classifieur comprend une chaîne qui indique la classification du fichier ou le format (par exemple, `json`) et le schéma du fichier. Pour les classifieurs personnalisés, vous définissez la

logique de création du schéma en fonction du type de classifieur. Les types de classifieur incluent la définition de schémas basés sur les modèles grok, les balises XML et les chemins d'accès JSON.

Si vous modifiez une définition de classifieur, toutes les données précédemment analysées à l'aide du classifieur ne sont pas reclassées. Un crawler garde trace des données précédemment analysées. Les nouvelles données sont classées avec le classifieur mis à jour, ce qui peut entraîner une mise à jour du schéma. Si le schéma de vos données a évolué, mettez à jour le classifieur pour prendre en compte les modifications de schéma lorsque votre crawler s'exécute. Pour reclasser les données et corriger un classificateur incorrect, créez un nouvel crawler avec le classificateur mis à jour.

Pour plus d'informations sur la création de classificateurs personnalisés dans AWS Glue, voir [Rédaction de classificateurs personnalisés pour divers formats de données](#).

Note

Si votre format de données est reconnu par l'un des classifieurs intégrés, vous n'avez pas besoin de créer un classifieur personnalisé.

Classificateurs intégrés

AWS Glue fournit des classificateurs intégrés pour différents formats, notamment JSON, CSV, les journaux Web et de nombreux systèmes de base de données.

If AWS Glue ne trouve pas de classificateur personnalisé qui correspond au format des données d'entrée avec une certitude absolue, il invoque les classificateurs intégrés dans l'ordre indiqué dans le tableau suivant. Les classifieurs intégrés renvoient un résultat pour indiquer si le format correspond à (`certainty=1.0`) ou ne correspond à (`certainty=0.0`). Le premier classifieur qui a `certainty=1.0` fournit la chaîne de classification et le schéma pour une table de métadonnées de votre Data Catalog.

Type de classifieur	Chaîne de classification	Remarques
Apache Avro	avro	Lit le schéma au début du fichier pour déterminer le format.
Apache ORC	orc	Lit les métadonnées du fichier pour déterminer le format.

Type de classifieur	Chaîne de classification	Remarques
Apache Parquet	parquet	Lit le schéma à la fin du fichier pour déterminer le format.
JSON	json	Lit le début du fichier pour déterminer le format.
Binaire JSON	bson	Lit le début du fichier pour déterminer le format.
xml	xml	Lit le début du fichier pour déterminer le format. AWS Glue détermine le schéma du tableau en fonction des balises XML du document. Pour plus d'informations sur la création d'un classifieur XML personnalisé pour spécifier les lignes du document, reportez-vous à la section Écriture de classifieurs XML personnalisés.
Amazon Ion	ion	Lit le début du fichier pour déterminer le format.
Journal Apache combiné	combined_apache	Détermine les formats de journaux par le biais d'un modèle grok.
Journal Apache	apache	Détermine les formats de journaux par le biais d'un modèle grok.
Journal du noyau Linux	linux_kernel	Détermine les formats de journaux par le biais d'un modèle grok.
Journal Microsoft	microsoft_log	Détermine les formats de journaux par le biais d'un modèle grok.
Journal Ruby	ruby_logger	Lit le début du fichier pour déterminer le format.
Journal Squid 3.x	squid	Lit le début du fichier pour déterminer le format.
Journal de surveillance Redis	redismonlog	Lit le début du fichier pour déterminer le format.

Type de classifieur	Chaîne de classification	Remarques
Journal Redis	redislog	Lit le début du fichier pour déterminer le format.
CSV	csv	Recherche les séparateurs suivants : virgule (,), barre verticale (), tabulation (\t), point-virgule (;) et Ctrl-A (\u0001). Ctrl-A est le caractère de contrôle Unicode pour Start Of Heading.
Amazon Redshift	redshift	Utilise la connexion JDBC pour importer les métadonnées.
MySQL	mysql	Utilise la connexion JDBC pour importer les métadonnées.
PostgreSQL	postgresql	Utilise la connexion JDBC pour importer les métadonnées.
Oracle Database	oracle	Utilise la connexion JDBC pour importer les métadonnées.
Microsoft SQL Server	sqlserver	Utilise la connexion JDBC pour importer les métadonnées.
Amazon DynamoDB	dynamodb	Lit les données de la table DynamoDB.

Les fichiers aux formats compressés suivants peuvent être classés :

- ZIP (pris en charge pour les archives contenant uniquement un fichier unique). Notez que Zip n'est pas correctement pris en charge dans d'autres services (en raison de l'archive).
- BZIP
- GZIP
- LZ4
- Snappy (pris en charge pour les formats Snappy standard et natifs Hadoop)

Classifieur CSV intégré

Le classificateur CSV intégré analyse le contenu du fichier CSV afin de déterminer le schéma d'un AWS Glue table. Le classifieur vérifie les délimiteurs suivants :

- Virgule (,)
- Pipe (|)
- Tabulation (\t)
- Point-virgule (;)
- Ctrl-A (\u0001)

Ctrl-A est le caractère de contrôle Unicode pour `Start Of Heading`.

Pour être classé comme CSV, le schéma de table doit avoir au moins deux colonnes et deux lignes de données. Le classifieur CSV utilise un certain nombre de méthodes heuristiques pour déterminer si un en-tête est présent dans un fichier donné. Si le classifieur ne peut pas déterminer un en-tête à partir de la première ligne de données, les en-têtes de colonne sont affichés en tant que `col1`, `col2`, `col3`, et ainsi de suite. Le classifieur CSV intégré détermine s'il convient de déduire un en-tête en évaluant les caractéristiques suivantes du fichier :

- Chaque colonne d'un en-tête potentiel s'analyse en tant que type de données `STRING`.
- À l'exception de la dernière colonne, chaque colonne d'un en-tête potentiel a un contenu de moins de 150 caractères. Pour autoriser un délimiteur de fin, la dernière colonne peut être vide dans le fichier.
- Chaque colonne d'un en-tête potentiel doit respecter les AWS Glue `regex` exigences relatives au nom d'une colonne.
- La ligne d'en-tête doit être suffisamment différente des lignes de données. Pour le déterminer, une ou plusieurs lignes doivent s'analyser autrement que de type `STRING`. Si toutes les colonnes sont de type `STRING`, la première ligne de données n'est pas suffisamment différente des lignes suivantes pour être utilisée comme en-tête.

Note

Si le classificateur CSV intégré ne crée pas votre AWS Glue comme vous le souhaitez, vous pouvez peut-être utiliser l'une des alternatives suivantes :

- Modifiez les noms de colonne du Data Catalog, définissez la structure `SchemaChangePolicy` sur LOG et définissez la configuration de sortie de la partition sur `InheritFromTable` pour les futures exécutions de l'crawler.
- Créez un classifieur grok personnalisés pour analyser les données et attribuez les colonnes de votre choix.
- Le classifieur CSV intégré crée les tables en faisant référence à `LazySimpleSerDe` comme bibliothèque de sérialisation, ce qui est un bon choix pour l'inférence du type. Toutefois, si les données CSV contiennent des chaînes entre guillemets, modifiez la définition de la table et remplacez la `SerDe` bibliothèque par `OpenCSVSerDe`. Ajustez les types déduits sur `STRING`, définissez la structure `SchemaChangePolicy` sur LOG et définissez la configuration de sortie des partitions sur `InheritFromTable` pour les futures exécutions de l'crawler. Pour plus d'informations sur `SerDe` les bibliothèques, consultez la section [SerDe Référence](#) du guide de l'utilisateur Amazon Athena.

Rédaction de classificateurs personnalisés pour divers formats de données

Vous pouvez fournir un classifieur personnalisé pour classer vos données dans AWS Glue. Vous pouvez créer un classificateur personnalisé à l'aide d'un modèle grok, d'une balise XML, d'une notation d' JavaScript objet (JSON) ou de valeurs séparées par des virgules (CSV). Un AWS Glue crawler appelle un classificateur personnalisé. Si le classifieur reconnaît les données, il renvoie la classification et le schéma des données à l'crawler. Il se peut que vous ayez besoin de définir un classifieur personnalisé si vos données ne correspondent à aucun classifieur intégré ou si vous souhaitez personnaliser les tables créées par l'crawler.

Pour plus d'informations sur la création d'un classificateur à l'aide du AWS Glue console, voir [Création de classificateurs à l'aide du AWS Glue console](#).

AWS Glue exécute les classificateurs personnalisés avant les classificateurs intégrés, dans l'ordre que vous spécifiez. Lorsqu'un crawler détecte un classifieur qui correspond aux données, la chaîne de classification et le schéma sont utilisés dans la définition des tables qui sont écrites dans votre AWS Glue Data Catalog.

Rubriques

- [Écriture de classifieurs personnalisés Grok](#)
- [Écriture de classifieurs XML personnalisés](#)
- [Écriture de classifieurs JSON personnalisés](#)

- [Écriture de classifieurs CSV personnalisés](#)

Écriture de classifieurs personnalisés Grok

Grok est un outil qui est utilisé pour analyser les données textuelles correspondant à un modèle donné. Un modèle grok est un ensemble nommé d'expressions régulières (regex) qui sont utilisées pour faire correspondre les données ligne par ligne. AWS Glue utilise des modèles de grok pour déduire le schéma de vos données. Lorsqu'un modèle de grok correspond à vos données, AWS Glue utilise le modèle pour déterminer la structure de vos données et les mapper dans des champs.

AWS Glue fournit de nombreux modèles intégrés, ou vous pouvez définir les vôtres. Vous pouvez créer un modèle grok à l'aide de modèles intégrés et de modèles personnalisés de votre définition de classifieur personnalisée. Vous pouvez personnaliser un modèle grok pour classer les formats de fichier texte personnalisés.

Note

AWS Glue Les classificateurs personnalisés grok utilisent la bibliothèque de GrokSerDe sérialisation pour les tables créées dans le. AWS Glue Data Catalog Si vous utilisez le AWS Glue Data Catalog avec Amazon Athena, Amazon EMR ou Redshift Spectrum, consultez la documentation relative à ces services pour obtenir des informations sur le support du. GrokSerDe Il est possible que vous rencontriez actuellement des problèmes lors de l'interrogation de tables créées avec le GrokSerDe à partir d'Amazon EMR et Redshift Spectrum.

Voici la syntaxe de base pour les composants d'un modèle grok :

```
%{PATTERN:field-name}
```

Les données correspondant au PATTERN nommé sont mises en correspondance avec la colonne `field-name` du schéma, avec le type de données par défaut `string`. Le cas échéant, le type de données du champ peut être converti en `byte`, `boolean`, `double`, `short`, `int`, `long`, ou `float` dans le schéma obtenu.

```
%{PATTERN:field-name:data-type}
```

Par exemple, pour convertir un champ `num` en type de données `int`, vous pouvez utiliser ce modèle :


```
%{NUMBER:num:int}
```

Les modèles peuvent être composés d'autres modèles. Par exemple, vous pouvez avoir un modèle pour un horodatage SYSLOG qui est défini par des modèles pour le mois, le jour du mois et l'heure (par exemple, Feb 1 06:25:43). Pour ces données, vous pourriez définir le schéma suivant:

```
SYSLOGTIMESTAMP %{MONTH} +%{MONTHDAY} %{TIME}
```

Note

Les modèles grok ne peuvent traiter qu'une ligne à la fois. Les modèles à plusieurs lignes ne sont pas pris en charge. De même, les sauts de ligne au sein d'un modèle ne sont pas pris en charge.

Valeurs personnalisées pour le classificateur grok

Lorsque vous définissez un classificateur grok, vous fournissez les valeurs suivantes pour créer le classificateur personnalisé.

Nom

Nom du classifieur.

Classification

Chaîne de texte écrite pour décrire le format des données qui est classé ; par exemple, `special-logs`.

Modèle grok

Ensemble des modèles appliqués au magasin de données afin de déterminer s'il y a une correspondance. Ces modèles proviennent de AWS Glue [les modèles intégrés](#) et tous les modèles personnalisés que vous définissez.

Voici un exemple de modèle grok :

```
%{TIMESTAMP_ISO8601:timestamp} \[%{MESSAGEPREFIX:message_prefix}\]  
%{CRAWLERLOGLEVEL:loglevel} : %{GREEDYDATA:message}
```

Lorsque les données correspondent à `TIMESTAMP_ISO8601`, une colonne de schéma `timestamp` est créée. Le comportement est similaire aux autres modèles nommés de l'exemple.

Modèles personnalisés

Modèles personnalisés facultatifs que vous définissez. Ces modèles sont référencés par le modèle `grok` qui classifie vos données. Vous pouvez référencer ces modèles personnalisés dans le modèle `grok` appliqué à vos données. Chaque modèle de composant personnalisé doit être sur une ligne distincte. La syntaxe des [expressions régulières \(regex\)](#) est utilisée pour définir le modèle.

Voici un exemple d'utilisation des modèles personnalisés :

```
CRAWLERLOGLEVEL (BENCHMARK|ERROR|WARN|INFO|TRACE)
MESSAGEPREFIX .*-.*-.*-.*-.*
```

Le premier modèle nommé personnalisé, `CRAWLERLOGLEVEL`, est une correspondance dans laquelle les données correspondent à l'une des chaînes énumérées. Le second modèle personnalisé, `MESSAGEPREFIX`, essaie de faire correspondre une chaîne de préfixe de message.

AWS Glue assure le suivi de l'heure de création, de la dernière mise à jour et de la version de votre classificateur.

Motifs intégrés

AWS Glue fournit de nombreux modèles courants que vous pouvez utiliser pour créer un classificateur personnalisé. Vous ajoutez un modèle nommé au `grok` `pattern` d'une définition de classifieur.

La liste suivante comprend une ligne pour chaque modèle. Dans chaque ligne, le nom du modèle est suivi de sa définition. La syntaxe des [expressions régulières \(regex\)](#) est utilisée pour définir le modèle.

```
#<noloc>&GLU;</noloc> Built-in patterns
USERNAME [a-zA-Z0-9._-]+
USER %{USERNAME:UNWANTED}
INT (?:[+-]?(?:[0-9]+))
BASE10NUM (?![0-9.+~])(?>[+-]?((?:[0-9]+(?:\.[0-9]+)?)|(?:\.[0-9]+)))
NUMBER (?:%{BASE10NUM:UNWANTED})
BASE16NUM (?![0-9A-Fa-f])(?:[+-]?((?:0x)?(?:[0-9A-Fa-f]+)))
```

```

BASE16FLOAT \b(?<![0-9A-Fa-f.])?(?:[+-]?(?:0x)?(?:[0-9A-Fa-f]+(?:\.[0-9A-Fa-f]*)?)|
(?:\.[0-9A-Fa-f]+))\b
BOOLEAN (?i)(true|false)

POSINT \b(?:[1-9][0-9]*)\b
NONNEGINT \b(?:[0-9]+)\b
WORD \b\w+\b
NOTSPACE \S+
SPACE \s*
DATA .*?
GREEDYDATA .*
#QUOTEDSTRING (?:(?<!\|)(?:\"(?:\\.|[^\\"'])*'|(?:\'(?:\\.|[^\\"'])*\'))|(?:`(?:\\.|[^\\"'])*`))
QUOTEDSTRING (?:(?<!\|)(?:>\"(?:\\.|[^\\"'])*+\"|'\"(?:\\.|[^\\"'])*+'|'\'(?:\\.|[^\\"'])*+\'|`\"(?:\\.|[^\\"'])*+`|`\'(?:\\.|[^\\"'])*+`))
UUID [A-Fa-f0-9]{8}-(?:[A-Fa-f0-9]{4}-){3}[A-Fa-f0-9]{12}

# Networking
MAC (?:%{CISCOMAC:UNWANTED}|%{WINDOWSMAC:UNWANTED}|%{COMMONMAC:UNWANTED})
CISCOMAC (?:([A-Fa-f0-9]{4}\.){2}[A-Fa-f0-9]{4})
WINDOWSMAC (?:([A-Fa-f0-9]{2}-){5}[A-Fa-f0-9]{2})
COMMONMAC (?:([A-Fa-f0-9]{2}:){5}[A-Fa-f0-9]{2})
IPV6 ((([0-9A-Fa-f]{1,4}:){7}([0-9A-Fa-f]{1,4}|:))|((([0-9A-Fa-f]{1,4}:){6}(:[0-9A-Fa-f]{1,4}|((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d)(\.((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d))){3})|:))|((([0-9A-Fa-f]{1,4}:){5}((([0-9A-Fa-f]{1,4}:){1,2})|((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d)(\.((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d))){3})|:))|((([0-9A-Fa-f]{1,4}:){4}((([0-9A-Fa-f]{1,4}:){1,3})|(([0-9A-Fa-f]{1,4})?:((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d)(\.((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d))){3}))|:))|((([0-9A-Fa-f]{1,4}:){3}((([0-9A-Fa-f]{1,4}:){1,4})|(([0-9A-Fa-f]{1,4}){0,2}:((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d)(\.((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d))){3}))|:))|((([0-9A-Fa-f]{1,4}:){2}((([0-9A-Fa-f]{1,4}:){1,5})|(([0-9A-Fa-f]{1,4}:){0,3}:((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d)(\.((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d))){3}))|:))|((([0-9A-Fa-f]{1,4}:){1}((([0-9A-Fa-f]{1,4}:){1,6})|(([0-9A-Fa-f]{1,4}:){0,4}:((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d)(\.((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d))){3}))|:))|(:((( [0-9A-Fa-f]{1,4}:){1,7})|(( [0-9A-Fa-f]{1,4}:){0,5}:((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d)(\.((25[0-5]|2[0-4]\d|1\d\d|1-9)?\d))){3}))|:)))(%+)?
IPV4 (?<![0-9])(?:([0-9]{1,3}|25[0-5]|2[0-4][0-9]|0-1)?[0-9]{1,3})[.](?:25[0-5]|2[0-4][0-9]|0-1)?[0-9]{1,3}[.](?:25[0-5]|2[0-4][0-9]|0-1)?[0-9]{1,3}[.](?:25[0-5]|2[0-4][0-9]|0-1)?[0-9]{1,3})(?![0-9])
IP (?:%{IPV6:UNWANTED}|%{IPV4:UNWANTED})
HOSTNAME \b(?:[0-9A-Za-z][0-9A-Za-z-_]{{0,62}}(?:\.(?:[0-9A-Za-z][0-9A-Za-z-_]{{0,62}}))*(\.|\b))
HOST %{HOSTNAME:UNWANTED}
IPORHOST (?:%{HOSTNAME:UNWANTED}|%{IP:UNWANTED})
HOSTPORT (?:%{IPORHOST}:%{POSINT:PORT})

```

```

# paths
PATH (?:%{UNIXPATH}|%{WINPATH})
UNIXPATH (?>/(?>[\w_!$@:.,~-]+|\\\.)*+
#UNIXPATH (?<![\w\|])(?:/[^\|\\s?]*)*+
TTY (?:/dev/(pts|tty([pq]))?)(\w+)?/?(?:[0-9]+))
WINPATH (?>[A-Za-z]+:|\\)(?:\\\[^\|\\?]*)*+
URIPROTO [A-Za-z]+(\+[A-Za-z+]+)?
URIHOST %{IPORHOST}(?:%{POSINT:port})?
# uripath comes loosely from RFC1738, but mostly from what Firefox
# doesn't turn into %XX
URIPATH (?:/[A-Za-z0-9$.+!*'(){}~,~:;=@#%_-]*)+
#URIPARAM \?(?:[A-Za-z0-9]+(?:=(?:[^\&]*))?(?:&(?:[A-Za-z0-9]+(?:=(?:[^\&]*))?)?)*)?
URIPARAM \?[A-Za-z0-9$.+!*'|(){}~,~:;=@#%&/=-;_?\\-\\[\\]]*
URIPATHPARAM %{URIPATH}(?:%{URIPARAM})?
URI %{URIPROTO}://(?:%{USER}(?:%{URIHOST})?(?:%{URIPATHPARAM})?

# Months: January, Feb, 3, 03, 12, December
MONTH \b(?:Jan(?:uary)?|Feb(?:ruary)?|Mar(?:ch)?|Apr(?:il)?|May|Jun(?:e)?|Jul(?:y)?|
Aug(?:ust)?|Sep(?:tember)?|Oct(?:ober)?|Nov(?:ember)?|Dec(?:ember)?)\b
MONTHNUM (?:0?[1-9]|1[0-2])
MONTHNUM2 (?:0[1-9]|1[0-2])
MONTHDAY (?:0?[1-9])|(?:[12][0-9])|(?:3[01])|[1-9])

# Days: Monday, Tue, Thu, etc...
DAY (?:Mon(?:day)?|Tue(?:sday)?|Wed(?:nesday)?|Thu(?:rsday)?|Fri(?:day)?|
Sat(?:urday)?|Sun(?:day)?)

# Years?
YEAR (?>\d\d){1,2}
# Time: HH:MM:SS
#TIME \d{2}:\d{2}(?::\d{2}(?:\.\d+))?)?
# TIME %{POSINT<24}:%{POSINT<60}(?::%{POSINT<60}(?:\.%{POSINT})?)?
HOUR (?:2[0123]|[01]?[0-9])
MINUTE (?:[0-5][0-9])
# '60' is a leap second in most time standards and thus is valid.
SECOND (?:0?[0-5]?[0-9]|60)(?:[:.,][0-9]+)?
TIME (?!<[0-9])%{HOUR}:%{MINUTE}(?::%{SECOND})(?![0-9])
# timestamp is YYYY/MM/DD-HH:MM:SS.UUUU (or something like it)
DATE_US %{MONTHNUM}[/-]%{MONTHDAY}[/-]%{YEAR}
DATE_EU %{MONTHDAY}[./-]%{MONTHNUM}[./-]%{YEAR}
DATESTAMP_US %{DATE_US}[- ]%{TIME}
DATESTAMP_EU %{DATE_EU}[- ]%{TIME}
ISO8601_TIMEZONE (?:Z|[-+]%{HOUR}(?::%{MINUTE}))

```

```

ISO8601_SECOND (?:%{SECOND}|60)
TIMESTAMP_ISO8601 %{YEAR}-%{MONTHNUM}-%{MONTHDAY}[T ]%{HOUR}:?%{MINUTE}(?:%{SECOND})?%{ISO8601_TIMEZONE}?
TZ (?:[PMCE][SD]T|UTC)
DATESTAMP_RFC822 %{DAY} %{MONTH} %{MONTHDAY} %{YEAR} %{TIME} %{TZ}
DATESTAMP_RFC2822 %{DAY}, %{MONTHDAY} %{MONTH} %{YEAR} %{TIME} %{ISO8601_TIMEZONE}
DATESTAMP_OTHER %{DAY} %{MONTH} %{MONTHDAY} %{TIME} %{TZ} %{YEAR}
DATESTAMP_EVENTLOG %{YEAR}%{MONTHNUM2}%{MONTHDAY}%{HOUR}%{MINUTE}%{SECOND}
CISCOTIMESTAMP %{MONTH} %{MONTHDAY} %{TIME}

# Syslog Dates: Month Day HH:MM:SS
SYSLOGTIMESTAMP %{MONTH} +%{MONTHDAY} %{TIME}
PROG (?:[\\w._/%-]+)
SYSLOGPROG %{PROG:program}(?:\\[%{POSINT:pid}\\])?
SYSLOGHOST %{IPORHOST}
SYSLOGFACILITY <%{NONNEGINT:facility}.%{NONNEGINT:priority}>
HTTPDATE %{MONTHDAY}/%{MONTH}/%{YEAR}:%{TIME} %{INT}

# Shortcuts
QS %{QUOTEDSTRING:UNWANTED}

# Log formats
SYSLOGBASE %{SYSLOGTIMESTAMP:timestamp} (?:%{SYSLOGFACILITY} )?%{SYSLOGHOST:logsource}
%{SYSLOGPROG}:

MESSAGESLOG %{SYSLOGBASE} %{DATA}

COMMONAPACHELOG %{IPORHOST:clientip} %{USER:ident} %{USER:auth}
\\[%{HTTPDATE:timestamp}\\] "(?:%{WORD:verb} %{NOTSPACE:request}(?: HTTP/
%{NUMBER:httpversion})?|%{DATA:rawrequest})" %{NUMBER:response} (?:%{Bytes:bytes=
%{NUMBER}}|-))
COMBINEDAPACHELOG %{COMMONAPACHELOG} %{QS:referrer} %{QS:agent}
COMMONAPACHELOG_DATATYPED %{IPORHOST:clientip} %{USER:ident;boolean} %{USER:auth}
\\[%{HTTPDATE:timestamp;date;dd/MMM/yyyy:HH:mm:ss Z}\\] "(?:%{WORD:verb;string}
%{NOTSPACE:request}(?: HTTP/%{NUMBER:httpversion;float})?|%{DATA:rawrequest})"
%{NUMBER:response;int} (?:%{NUMBER:bytes;long}}|-)

# Log Levels
LOGLEVEL ([A|a]lert|ALERT|[T|t]race|TRACE|[D|d]ebug|DEBUG|[N|n]otice|NOTICE|[I|i]nfo|
INFO|[W|w]arn(?:ing)?|WARN(?:ING)?|[E|e]rr(?:or)?|ERR(?:OR)?|[C|c]rit(?:ical)?|
CRIT(?:ICAL)?|[F|f]atal|FATAL|[S|s]evere|SEVERE|EMERG(?:ENCY)?|[Ee]merg(?:ency)?)

```

Écriture de classifieurs XML personnalisés

Le langage XML définit la structure d'un document avec l'utilisation de balises dans le fichier. Avec un classifieur XML personnalisé, vous pouvez spécifier le nom de la balise utilisé pour définir une ligne.

Valeurs de classificateur personnalisées pour un classificateur XML

Lorsque vous définissez un classificateur XML, vous fournissez les valeurs suivantes à AWS Glue pour créer le classificateur. Le champ de classification du classifieur est défini sur `xml`.

Nom

Nom du classifieur.

Balise de ligne

Nom de balise XML qui définit une ligne de table du document XML, sans crochets `< >`. Ce nom doit respecter les règles XML relatives aux balises.

Note

L'élément contenant les données de ligne ne peut pas être un élément auto-fermant vide. Par exemple, cet élément vide n'est pas analysé par AWS Glue:

```
<row att1="xx" att2="yy" />
```

Les éléments vides peuvent être écrits comme suit :

```
<row att1="xx" att2="yy"> </row>
```

AWS Glue assure le suivi de l'heure de création, de la dernière mise à jour et de la version de votre classificateur.

Par exemple, supposons que vous disposez du fichier XML suivant. Pour créer un AWS Glue table contenant uniquement des colonnes pour l'auteur et le titre, créez un classificateur dans AWS Glue

console avec le tag Row comme AnyCompany. Ensuite, ajoutez et exécutez un crawler qui utilise ce classifieur personnalisé.

```
<?xml version="1.0"?>
<catalog>
  <book id="bk101">
    <AnyCompany>
      <author>Rivera, Martha</author>
      <title>AnyCompany Developer Guide</title>
    </AnyCompany>
  </book>
  <book id="bk102">
    <AnyCompany>
      <author>Stiles, John</author>
      <title>Style Guide for AnyCompany</title>
    </AnyCompany>
  </book>
</catalog>
```

Écriture de classifieurs JSON personnalisés

JSON est un format d'échange de données. Il définit les structures de données avec des paires nom-valeur ou une liste ordonnée de valeurs. Grâce à un classifieur JSON personnalisé, vous pouvez spécifier le chemin d'accès JSON vers une structure de données utilisée pour définir le schéma de votre table.

Valeurs de classificateur personnalisées dans AWS Glue

Lorsque vous définissez un classificateur JSON, vous fournissez les valeurs suivantes à AWS Glue pour créer le classificateur. Le champ de classification du classifieur est défini sur `json`.

Nom

Nom du classifieur.

Chemin JSON

Chemin d'accès JSON qui pointe vers un objet utilisé pour définir un schéma de table. Le chemin JSON peut être écrit en notation point ou en notation crochet. Les opérateurs suivants sont pris en charge:

Description

Élément racine d'un objet JSON. Toutes les expressions de chemin commencent par cet élément.

Caractère générique. Disponible partout où un nom ou une valeur numérique sont obligatoires dans le chemin JSON.

Enfant à notation point. Spécifie un champ enfant dans un objet JSON.

Enfant à notation crochet. Spécifie un champ enfant dans un objet JSON. Un seul champ enfant peut être spécifié.

Index de tableau. Spécifie la valeur d'un tableau par son index.

AWS Glue assure le suivi de l'heure de création, de la dernière mise à jour et de la version de votre classificateur.

Exemple Utilisation d'un classifieur JSON pour extraire les enregistrements d'un tableau

Supposons que vos données JSON soient un tableau d'enregistrements. Par exemple, les premières lignes de votre fichier peuvent se présenter ainsi :

```
[
  {
    "type": "constituency",
    "id": "ocd-division/country:us/state:ak",
    "name": "Alaska"
  },
  {
    "type": "constituency",
    "id": "ocd-division/country:us/state:al/cd:1",
    "name": "Alabama's 1st congressional district"
  },
  {
    "type": "constituency",
    "id": "ocd-division/country:us/state:al/cd:2",
    "name": "Alabama's 2nd congressional district"
  },
]
```



```
{
  "type": "constituency",
  "id": "ocd-division/country:us/state:al/cd:3",
  "name": "Alabama's 3rd congressional district"
},
{
  "type": "constituency",
  "id": "ocd-division/country:us/state:al/cd:4",
  "name": "Alabama's 4th congressional district"
},
{
  "type": "constituency",
  "id": "ocd-division/country:us/state:al/cd:5",
  "name": "Alabama's 5th congressional district"
},
{
  "type": "constituency",
  "id": "ocd-division/country:us/state:al/cd:6",
  "name": "Alabama's 6th congressional district"
},
{
  "type": "constituency",
  "id": "ocd-division/country:us/state:al/cd:7",
  "name": "Alabama's 7th congressional district"
},
{
  "type": "constituency",
  "id": "ocd-division/country:us/state:ar/cd:1",
  "name": "Arkansas's 1st congressional district"
},
{
  "type": "constituency",
  "id": "ocd-division/country:us/state:ar/cd:2",
  "name": "Arkansas's 2nd congressional district"
},
{
  "type": "constituency",
  "id": "ocd-division/country:us/state:ar/cd:3",
  "name": "Arkansas's 3rd congressional district"
},
{
  "type": "constituency",
  "id": "ocd-division/country:us/state:ar/cd:4",
  "name": "Arkansas's 4th congressional district"
}
```

```
}  
]
```

Lorsque vous exécutez un crawler à l'aide du classifieur JSON intégré, le fichier entier est utilisé pour définir le schéma. Comme vous ne spécifiez pas de chemin JSON, le crawler traite les données comme un objet, en l'occurrence un simple tableau. Par exemple, le schéma pourrait s'apparenter à ce qui suit :

```
root  
|-- record: array
```

Cependant, pour créer un schéma basé sur chaque enregistrement du tableau JSON, créez un classifieur JSON personnalisé et spécifiez le chemin JSON comme `$[*]`. Lorsque vous spécifiez ce chemin JSON, le classifieur interroge tous les 12 enregistrements du tableau pour déterminer le schéma. Le schéma obtenu contient des champs séparés pour chaque objet, comme dans l'exemple qui suit :

```
root  
|-- type: string  
|-- id: string  
|-- name: string
```

Exemple Utilisation d'un classifieur JSON pour n'examiner que certaines parties d'un fichier

Supposons que vos données JSON suivent le modèle de l'exemple de fichier JSON `s3://awsglue-datasets/examples/us-legislators/all/areas.json` extrait de <http://everypolitician.org/>. Les exemples d'objets dans le fichier JSON se présentent comme suit :

```
{  
  "type": "constituency",  
  "id": "ocd-division/country:us/state:ak",  
  "name": "Alaska"  
}  
{  
  "type": "constituency",  
  "identifiers": [  
    {  
      "scheme": "dmoz",
```

```

    "identifiant": "Regional\\North_America\\United_States\\Alaska\\"
  },
  {
    "scheme": "freebase",
    "identifiant": "\\m\\0hjy"
  },
  {
    "scheme": "fips",
    "identifiant": "US02"
  },
  {
    "scheme": "quora",
    "identifiant": "Alaska-state"
  },
  {
    "scheme": "britannica",
    "identifiant": "place\\Alaska"
  },
  {
    "scheme": "wikidata",
    "identifiant": "Q797"
  }
],
"other_names": [
  {
    "lang": "en",
    "note": "multilingual",
    "name": "Alaska"
  },
  {
    "lang": "fr",
    "note": "multilingual",
    "name": "Alaska"
  },
  {
    "lang": "nov",
    "note": "multilingual",
    "name": "Alaska"
  }
],
"id": "ocd-division\\country:us\\state:ak",
"name": "Alaska"
}

```

Lorsque vous exécutez un crawler à l'aide du classifieur JSON intégré, le fichier entier est utilisé pour créer le schéma. Vous pouvez vous retrouver avec un schéma tel que celui-ci :

```
root
|-- type: string
|-- id: string
|-- name: string
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- other_names: array
|   |-- element: struct
|   |   |-- lang: string
|   |   |-- note: string
|   |   |-- name: string
```

Cependant, pour créer un schéma en n'utilisant que l'objet « id », créez un classifieur JSON personnalisé et spécifiez le chemin JSON comme \$.id. Le schéma est donc basé uniquement sur le champ « id » :

```
root
|-- record: string
```

Les quelques premières lignes de données extraites avec ce schéma se présentent ainsi :

```
{"record": "ocd-division/country:us/state:ak"}
{"record": "ocd-division/country:us/state:al/cd:1"}
{"record": "ocd-division/country:us/state:al/cd:2"}
{"record": "ocd-division/country:us/state:al/cd:3"}
{"record": "ocd-division/country:us/state:al/cd:4"}
{"record": "ocd-division/country:us/state:al/cd:5"}
{"record": "ocd-division/country:us/state:al/cd:6"}
{"record": "ocd-division/country:us/state:al/cd:7"}
{"record": "ocd-division/country:us/state:ar/cd:1"}
{"record": "ocd-division/country:us/state:ar/cd:2"}
```

```

{"record": "ocd-division/country:us/state:ar/cd:3"}
{"record": "ocd-division/country:us/state:ar/cd:4"}
{"record": "ocd-division/country:us/state:as"}
{"record": "ocd-division/country:us/state:az/cd:1"}
{"record": "ocd-division/country:us/state:az/cd:2"}
{"record": "ocd-division/country:us/state:az/cd:3"}
{"record": "ocd-division/country:us/state:az/cd:4"}
{"record": "ocd-division/country:us/state:az/cd:5"}
{"record": "ocd-division/country:us/state:az/cd:6"}
{"record": "ocd-division/country:us/state:az/cd:7"}

```

Pour créer un schéma basé sur un objet profondément imbriqué, comme « identifier », dans le fichier JSON, vous pouvez créer un classifieur JSON personnalisé et spécifier le chemin JSON comme ainsi : `$.identifiers[*].identifier`. Bien que le schéma soit similaire à l'exemple précédent, il repose sur un autre objet du fichier JSON.

Le schéma se présente comme suit :

```

root
|-- record: string

```

L'affichage des quelques premières lignes de données de la table montre que le schéma est basé sur les données de l'objet « identifier » :

```

{"record": "Regional/North_America/United_States/Alaska/"}
{"record": "/m/0hjy"}
{"record": "US02"}
{"record": "5879092"}
{"record": "4001016-8"}
{"record": "destination/alaska"}
{"record": "1116270"}
{"record": "139487266"}
{"record": "n79018447"}
{"record": "01490999-8dec-4129-8254-eef6e80fadc3"}
{"record": "Alaska-state"}
{"record": "place/Alaska"}
{"record": "Q797"}
{"record": "Regional/North_America/United_States/Alabama/"}
{"record": "/m/0gyh"}
{"record": "US01"}

```

```
{"record": "4829764"}  
{"record": "4084839-5"}  
{"record": "161950"}  
{"record": "131885589"}
```

Pour créer une table basée sur un autre objet profondément imbriqué, tel que le champ « name » du tableau « other_names » du fichier JSON, vous pouvez créer un classifieur JSON personnalisé et spécifier le chemin JSON ainsi : \$.other_names[*].name. Bien que le schéma soit similaire à l'exemple précédent, il repose sur un autre objet du fichier JSON. Le schéma se présente comme suit :

```
root  
|-- record: string
```

L'affichage des quelques premières lignes de données de la table montre qu'il est basé sur les données de l'objet « name » du tableau « other_names » :

```
{"record": "Alaska"}  
{"record": "Alaska"}  
{"record": "Аляска"}  
{"record": "Alaska"}  
{"record": "Alaska"}  
{"record": "Alaska"}  
{"record": "Alaska"}  
{"record": "Alaska"}  
{"record": "Alaska"}  
{"record": "#####"}  
{"record": "#####"}  
{"record": "#####"}  
{"record": "Alaska"}  
{"record": "Alyaska"}  
{"record": "Alaska"}  
{"record": "Alaska"}  
{"record": "Штат Аляска"}  
{"record": "Аляска"}  
{"record": "Alaska"}  
{"record": "#####"}  

```

Écriture de classifieurs CSV personnalisés

Les classifieurs CSV personnalisés vous permettent de spécifier des types de données pour chaque colonne dans le champ de classifieur CSV personnalisé. Vous pouvez spécifier le type de données de chaque colonne en les séparant par des virgules. En spécifiant les types de données, vous pouvez remplacer les types de données déduits par les Crawlers et vous assurer que les données seront classées de manière appropriée.

Vous pouvez définir le fichier CSV SerDe pour le traitement dans le classificateur, qui sera appliqué dans le catalogue de données.

Lorsque vous créez un classifieur personnalisé, vous pouvez également le réutiliser pour différents Crawlers.

- Les fichiers CSV contenant uniquement des en-têtes (pas de données) sont classés comme UNKNOWN (INCONNU), car les informations fournies ne sont pas suffisantes. Si vous spécifiez « Has headings » (Comporte des en-têtes) pour le fichier CSV dans l'option Column headings (En-têtes de colonne) et que vous fournissez les types de données, nous pouvons classer ces fichiers correctement.

Vous pouvez utiliser un classifieur CSV personnalisé pour déduire le schéma de différents types de données CSV. Les attributs personnalisés que vous pouvez fournir à votre classificateur incluent des délimiteurs, une SerDe option CSV, des options concernant l'en-tête et l'opportunité d'effectuer certaines validations sur les données.

Valeurs de classificateur personnalisées dans AWS Glue

Lorsque vous définissez un classificateur CSV, vous fournissez les valeurs suivantes à AWS Glue pour créer le classificateur. Le champ de classification du classifieur est défini sur csv.

Nom du classifieur

Nom du classifieur.

SerDe CSV

Définit le CSV SerDe pour le traitement dans le classificateur, qui sera appliqué dans le catalogue de données. Les options sont Open CSV SerDe, Lazy Simple SerDe et None. Vous pouvez spécifier la valeur None lorsque vous souhaitez que le Crawler effectue la détection.

Délimiteur de colonne

Symbole personnalisé pour indiquer ce qui sépare chaque entrée de colonne dans la ligne. Saisissez un caractère Unicode. Si vous ne parvenez pas à saisir votre délimiteur, vous pouvez le coller. Cela fonctionne pour les caractères imprimables, y compris ceux que votre système ne prend pas en charge (généralement affichés comme □).

Symbole de guillemets

Symbole personnalisé pour indiquer ce qui combine le contenu en une seule valeur de colonne. Doit être différent du délimiteur de colonne. Saisissez un caractère Unicode. Si vous ne parvenez pas à saisir votre délimiteur, vous pouvez le coller. Cela fonctionne pour les caractères imprimables, y compris ceux que votre système ne prend pas en charge (généralement affichés comme □).

En-têtes de colonnes

Indique le comportement à suivre pour détecter les en-têtes de colonnes dans le fichier CSV. Si votre fichier CSV personnalisé a des en-têtes de colonnes, entrez une liste séparée par des virgules de ces en-têtes de colonnes.

Options de traitement : Autoriser les fichiers avec une seule colonne

Active le traitement des fichiers qui ne contiennent qu'une seule colonne.

Options de traitement : Supprimer l'espace blanc avant d'identifier les valeurs de colonne

Spécifie s'il convient de couper les valeurs avant d'identifier le type des valeurs de colonne.

Types de données personnalisés – facultatif

Saisissez le type de données personnalisé en le séparant par une virgule. Spécifie les types de données personnalisés dans le fichier CSV. Le type de données personnalisé doit être un type de données pris en charge. Les types de données pris en charge sont les suivants : « BINARY », « BOOLEAN », « DATE », « DECIMAL », « DOUBLE », « FLOAT », « INT », « LONG », « SHORT », « STRING », « TIMESTAMP ». Les types de données non pris en charge affichent une erreur.

Création de classificateurs à l'aide du AWS Glue console

Un classifieur détermine le schéma de vos données. Vous pouvez écrire un classifieur personnalisé et pointer dessus à partir d' AWS Glue.

Création de classifieurs

Pour ajouter un classificateur dans AWS Glue console, choisissez Ajouter un classificateur. Lorsque vous définissez un classifieur, vous fournissez des valeurs pour les éléments suivants :

- Classifier name (Nom du classifieur) – indiquez un nom unique pour votre classifieur.
- Classifier type (Type de classifieur) – type de classification des tables déduites par ce classifieur.
- Last updated (Dernière mise à jour) – heure de la dernière mise à jour de ce classifieur.

Nom du classifieur

Indiquez un nom unique pour votre classifieur.

Type de classifieur

Choisissez le type de classifieur à créer.

Selon le type de classificateur que vous choisissez, configurez les propriétés suivantes pour votre classificateur :

Grok

- Classement

Décrivez le format ou le type des données classées ou fournissez une étiquette personnalisée.

- Modèle grok

Cela est utilisé pour analyser vos données dans un schéma structuré. Le modèle grok se compose de schémas nommés qui décrivent le format de votre magasin de données. Vous écrivez ce modèle de grok en utilisant les modèles intégrés nommés fournis par AWS Glue et les modèles personnalisés que vous rédigez et incluez dans le champ Modèles personnalisés. Bien que les résultats du débogueur grok puissent ne pas correspondre à ceux de AWS Glue exactement, nous vous suggérons d'essayer votre modèle en utilisant des exemples de données avec un débogueur grok. Vous pouvez trouver des débogueurs grok sur le Web. Les modèles intégrés nommés fournis par AWS Glue sont généralement compatibles avec les modèles grok disponibles sur le Web.

Créez votre modèle grok en ajoutant de manière itérative des modèles nommés et vérifiez vos résultats dans un débogueur. Cette activité vous donne l'assurance que lorsque AWS Glue crawler exécute votre modèle grok, vos données peuvent être analysées.

- Modèles personnalisés

Pour les classifieurs grok, il s'agit de blocs de construction facultatifs pour le Grok pattern (Modèle grok) que vous écrivez. Lorsque les modèles intégrés ne peuvent pas analyser vos données, vous pouvez avoir besoin d'écrire un modèle personnalisé. Ces modèles personnalisés sont définis dans ce champ et référencés dans le champ Grok pattern (Modèle grok). Chaque modèle personnalisé est défini sur une ligne distincte. À l'image d'un modèle intégré, il se compose d'une définition de modèle nommé qui utilise une syntaxe d'[expression régulière \(regex\)](#).

L'exemple suivant utilise le nom MESSAGEPREFIX, suivi d'une définition d'expression régulière à appliquer à vos données afin de déterminer si elles suivent le modèle.

```
MESSAGEPREFIX .*-.*-.*-.*-.*
```

XML

- Balise de ligne

Pour les classifieurs XML, il s'agit du nom de la balise XML qui définit une ligne de table dans le document XML. Tapez le nom sans crochets < >. Ce nom doit respecter les règles XML relatives aux balises.

Pour de plus amples informations, veuillez consulter [Écriture de classifieurs XML personnalisés](#).

JSON

- Chemin JSON

Pour les classifieurs JSON, il s'agit du chemin d'accès JSON à l'objet, au tableau ou à la valeur qui définit une ligne de la table en cours de création. Tapez le nom entre points ou crochets en utilisant la syntaxe JSON AWS Glue opérateurs pris en charge.

Pour en savoir plus, consultez la liste des opérateurs dans [Écriture de classifieurs JSON personnalisés](#).

CSV

- Délimiteur de colonne

Caractère ou symbole unique pour indiquer ce qui sépare chaque entrée de colonne dans la ligne. Choisissez le délimiteur dans la liste ou sélectionnez `Other` pour saisir un délimiteur personnalisé.

- Symbole de guillemets

Caractère ou symbole unique pour indiquer ce qui combine le contenu en une seule valeur de colonne. Doit être différent du délimiteur de colonne. Choisissez le symbole de guillemet dans la liste ou sélectionnez `Other` pour saisir un caractère de guillemet personnalisé.

- En-têtes de colonnes

Indique le comportement à suivre pour détecter les en-têtes de colonnes dans le fichier CSV. Vous pouvez choisir `Has headings`, `No headings` ou `Detect headings`. Si votre fichier CSV personnalisé a des en-têtes de colonnes, entrez une liste séparée par des virgules de ces en-têtes de colonnes.

- Autoriser les fichiers avec une seule colonne

Pour être classé comme CSV, les données doivent avoir au moins deux colonnes et deux lignes de données. Utilisez cette option pour autoriser le traitement des fichiers qui ne contiennent qu'une seule colonne.

- Supprimer les espaces avant d'identifier les valeurs de colonne

Cette option spécifie s'il convient de couper les valeurs avant d'identifier le type des valeurs de colonne.

- Type de données personnalisé

(Facultatif) – Saisissez des types de données personnalisés dans une liste délimitée par des virgules. Les types de données pris en charge sont les suivants : « `BINARY` », « `BOOLEAN` », « `DATE` », « `DECIMAL` », « `DOUBLE` », « `FLOAT` », « `INT` », « `LONG` », « `SHORT` », « `STRING` », « `TIMESTAMP` ».

- SerDe CSV

(Facultatif) - A SerDe pour le traitement du CSV dans le classificateur, qui sera appliqué dans le catalogue de données. Choisissez Open CSV SerDe, Lazy Simple SerDe ou None. Vous pouvez spécifier la valeur None lorsque vous souhaitez que le Crawler effectue la détection.

Pour de plus amples informations, veuillez consulter [Rédaction de classificateurs personnalisés pour divers formats de données](#).

Affichage des classifieurs

Pour voir la liste de tous les classificateurs que vous avez créés, ouvrez AWS Glue console sur <https://console.aws.amazon.com/glue/>, et choisissez l'onglet Classifiers.

La liste affiche les propriétés suivantes sur chaque classifieur :

- Classifier (Classifieurs) – nom du classifieur. Lorsque vous créez un classifieur, vous devez indiquer un nom pour celui-ci.
- Classification – type de classification des tables déduites par ce classifieur.
- Last updated (Dernière mise à jour) – heure de la dernière mise à jour de ce classifieur.

Gestion des classifieurs

À partir de la liste des classificateurs figurant dans le AWS Glue console, vous pouvez ajouter, modifier et supprimer des classificateurs. Pour afficher plus de détails sur un classifieur, choisissez le nom du classifieur dans la liste. Les détails incluent les informations que vous avez définies lors de la création du classifieur.

Configuration d'un crawler

Un robot d'exploration accède à votre banque de données, identifie les métadonnées et crée des définitions de tables dans le AWS Glue Data Catalog Le volet Crawlers de la AWS Glue console répertorie tous les robots d'exploration que vous créez. La liste affiche le statut et les métriques de la dernière exécution de votre crawler.

Cette rubrique décrit le step-by-step processus de configuration d'un robot d'exploration, en abordant des aspects essentiels tels que la configuration des paramètres du robot, la définition des sources de données à explorer, le paramétrage de la sécurité et la gestion des données analysées.

Rubriques

- [Étape 1 : Configurer les propriétés du crawler](#)
- [Étape 2 : Choisir des sources de données et des classificateurs.](#)
- [Étape 3 : Configurer les paramètres de sécurité](#)
- [Étape 4 : Configurer la sortie et la planification](#)
- [Étape 5 : Vérification et création](#)

Étape 1 : Configurer les propriétés du crawler

Pour configurer un robot d'exploration

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>. Sélectionnez Crawlers dans le panneau de navigation.
2. Cliquez sur Créer un Crawler, puis suivez les instructions de l'assistant Ajouter un Crawler. L'assistant vous indiquera les étapes nécessaires à la création d'un robot d'exploration. Si vous souhaitez ajouter des classificateurs personnalisés pour définir le schéma, consultez. [Définition et gestion des classificateurs](#)
3. Saisissez un nom pour votre Crawler et une description (facultatif). Le cas échéant, vous pouvez baliser votre crawler avec une clé de balise et avec une valeur de balise facultative. Une fois créées, les clés de balise sont en lecture seule. Utilisez des identifications sur certaines ressources pour mieux les organiser et les identifier. Pour plus d'informations, voir AWS tags in AWS Glue.

Nom

Le nom peut contenir des lettres (A à Z), des chiffres (0 à 9), des tirets (-) ou des traits de soulignement (_) et jusqu'à 255 caractères.

Description

Les descriptions peuvent comporter jusqu'à 2 048 caractères.

Balises

Utilisez des balises pour identifier et organiser vos ressources. Pour plus d'informations, consultez les ressources suivantes :

- [AWS tags dans AWS Glue](#)

Étape 2 : Choisir des sources de données et des classificateurs.

Configurez ensuite les sources de données et les classificateurs pour le robot d'exploration.

Pour plus d'informations sur les sources de données prises en charge, consultez [Sources de données prises en charge pour l'exploration](#).

Configuration de source de données

Sélectionnez l'option appropriée pour Vos données sont-elles déjà mappées à AWS Glue des tables ? choisissez « Pas encore » ou « Oui ». Par défaut, Pas encore est déjà sélectionné.

L'crawler peut accéder aux magasins de données directement en tant que source de l'analyse, ou il peut utiliser des tables de Data Catalog existantes en tant que source. Si l'crawler utilise des tables de catalogue existantes, il analyse les magasins de données qui sont spécifiés par ces tables de catalogue.

- Pas encore : Sélectionnez une ou plusieurs sources de données à analyser. Un crawler peut analyser plusieurs magasins de données de différents types (Amazon S3, JDBC, etc.).

Vous ne pouvez configurer qu'un seul magasin de données à la fois. Après avoir fourni les informations de connexion et inclus les chemins et les modèles d'exclusion, vous avez alors la possibilité d'ajouter un autre magasin de données.

- Oui : sélectionnez les tables existantes dans votre AWS Glue Catalogue de données. Les tables de catalogue spécifient les magasins de données à analyser. L'crawler peut uniquement analyser des tables de catalogue en une seule exécution ; il ne peut pas combiner dans d'autres types de source.

Généralement, pour spécifier une table de catalogue en tant que source, c'est que vous avez créé la table manuellement (parce que vous connaissiez déjà la structure du magasin de données) et vous voulez qu'un crawler garde la table à jour, y compris ajouter de nouvelles partitions. Pour une discussion sur d'autres raisons, consultez [Mise à jour de tables Data Catalog créées manuellement à l'aide d'crawlers](#).

Lorsque vous spécifiez des tables existantes en tant que type source d'crawler, les conditions suivantes s'appliquent :

- Le nom de la base de données est facultatif.
- Seules les tables de catalogue qui spécifient les magasins de données Amazon S3, Amazon DynamoDB ou Delta Lake sont autorisées.

- Aucune nouvelle table de catalogue n'est créée lorsque l'crawler s'exécute. Les tables sont mises à jour selon les besoins, y compris en ajoutant de nouvelles partitions.
- Les objets supprimés trouvés dans les magasins de données sont ignorés ; aucune table de catalogue n'est supprimée. Au lieu de cela, l'crawler rédige un message de journal. (SchemaChangePolicy.DeleteBehavior=LOG)
- L'option de configuration de l'crawler pour créer un seul schéma pour chaque chemin Amazon S3 est activée par défaut et ne peut pas être désactivée. (TableGroupingPolicy=CombineCompatibleSchemas) Pour plus d'informations, consultez [Création d'un schéma unique pour chaque chemin d'inclusion Amazon S3](#).
- Vous ne pouvez pas combiner des tables de catalogue en tant que source avec d'autres types de source (par exemple, Amazon S3 ou Amazon DynamoDB).

Pour utiliser les tables Delta, créez d'abord une table Delta à l'aide d'Athena DDL ou de l'API. AWS Glue

À l'aide d'Athena, définissez l'emplacement de votre dossier Amazon S3 et le type de table sur « DELTA ».

```
CREATE EXTERNAL TABLE database_name.table_name
LOCATION 's3://bucket/folder/'
TBLPROPERTIES ('table_type' = 'DELTA')
```

À l'aide de l' AWS Glue API, spécifiez le type de table dans la carte des paramètres de table. Les paramètres de la table doivent inclure la paire clé/valeur suivante. Pour plus d'informations sur la création d'une table, consultez la [documentation Boto3 pour create_table](#).

```
{
    "table_type": "delta"
}
```

Sources de données

Sélectionnez ou ajoutez la liste des sources de données à analyser par le crawler.

(Facultatif) Si vous choisissez JDBC comme source de données, vous pouvez utiliser vos propres pilotes JDBC lorsque vous spécifiez l'accès à la connexion où les informations du pilote sont stockées.

Chemin à inclure

Lors de l'évaluation des éléments à inclure ou exclure dans une analyse, un crawler commence par évaluer le chemin d'inclusion requis. Pour les magasins de données Amazon S3, MongoDB, MongoDB Atlas, Amazon DocumentDB (compatible avec MongoDB) et les magasins de données relationnelles, vous devez spécifier un chemin d'inclusion.

Pour un magasin de données Amazon S3

Déterminez si vous souhaitez spécifier un chemin dans ce compte ou dans un autre compte, puis parcourez les chemins Amazon S3 pour en choisir un.

Pour les magasins de données Amazon S3, la syntaxe de chemin d'accès inclut est `bucket-name/folder-name/file-name.ext`. Pour analyser tous les objets d'un compartiment, spécifiez juste le nom du compartiment dans le chemin d'inclusion. Le modèle d'exclusion est relatif au chemin d'inclusion

Pour un magasin de données Delta Lake

Spécifiez un ou plusieurs chemins Amazon S3 vers les tables Delta sous la forme `s3://bucket/prefix/object`.

Pour un magasin de données Iceberg ou Hudi

Spécifiez un ou plusieurs chemins Amazon S3 contenant des dossiers contenant des métadonnées de table Iceberg ou Hudi sous la forme `s3:///bucket.prefix`

Pour les magasins de données Iceberg et Hudi, le dossier Iceberg/Hudi peut se trouver dans un dossier enfant du dossier racine. Le Crawler examine tous les dossiers situés sous un chemin à la recherche d'un dossier Hudi.

Pour un magasin de données JDBC

Entrez `<database>/<schema>/<table>` ou `<database>/<table>`, selon le produit de base de données. Oracle Database et MySQL ne prennent pas en charge le schéma dans le chemin. Vous pouvez remplacer le pourcentage (%) par `<schema>` ou `<table>`. Par exemple, pour une base de données Oracle avec l'identificateur système (SID) `orcl`, entrez `orcl/%` pour importer toutes les tables auxquelles l'utilisateur nommé dans la connexion a accès.

Important

Ce champ est sensible à la casse.

 Note

Si vous choisissez d'apporter vos propres versions de pilotes JDBC, AWS Glue les crawlers consommeront des ressources dans AWS Glue jobs et compartiments Amazon S3 pour garantir que le pilote que vous avez fourni est exécuté dans votre environnement. L'utilisation supplémentaire des ressources sera reflétée sur votre compte. Les pilotes sont limités aux propriétés décrites dans la section [Ajout d'un AWS Glue connexion](#).

Pour un magasin de données MongoDB, MongoDB Atlas ou Amazon DocumentDB

Pour MongoDB, MongoDB Atlas et Amazon DocumentDB (compatible avec MongoDB), la syntaxe est `database/collection`.

Pour les magasins de données JDBC, la syntaxe est `database-name/schema-name/table-name` ou `database-name/table-name`. La syntaxe varie selon que le moteur de base de données prend en charge ou pas les schémas dans une base de données. Par exemple, pour les moteurs de base de données tels que MySQL ou Oracle, ne spécifiez pas `schema-name` dans votre chemin d'inclusion. Vous pouvez remplacer le signe pourcentage (%) d'un schéma ou d'une table dans le chemin d'inclusion pour représenter tous les schémas ou toutes les tables d'une base de données. Vous ne pouvez pas remplacer le signe pourcentage (%) pour la base de données dans le chemin d'inclusion.

Profondeur maximale d'indexation (pour les magasins de données Iceberg ou Hudi uniquement)

Définit la profondeur maximale du chemin Amazon S3 que le Crawler peut parcourir pour découvrir le dossier de métadonnées Iceberg ou Hudi dans votre chemin Amazon S3. L'objectif de ce paramètre est de limiter la durée d'exécution du Crawler. La valeur par défaut est 10 et la valeur maximale est 20.

Modèles d'exclusion

Ils vous permettent d'exclure certains fichiers ou tables de l'analyse. Le chemin à exclure est relatif par rapport au chemin à inclure. Par exemple, pour exclure une table de votre magasin de données JDBC, tapez le nom de la table dans le chemin d'exclusion.

Un robot d'exploration se connecte à un magasin de données JDBC à l'aide d'un AWS Glue connexion contenant une chaîne de connexion URI JDBC. Le robot d'exploration a uniquement accès aux objets du moteur de base de données à l'aide du nom d'utilisateur et du mot de

passer JDBC figurant dans le AWS Glue connexion. L'crawler peut uniquement créer des tables auxquelles il peut accéder via la connexion JDBC. Une fois que l'crawler a accédé au moteur de base de données avec l'URI JDBC, le chemin d'inclusion est utilisé pour déterminer quelles tables du moteur de base de données sont créées dans Data Catalog. Par exemple, avec MySQL, si vous spécifiez un chemin d'inclusion `MyDatabase/%`, toutes les tables de `MyDatabase` sont créées dans Data Catalog. Lors de l'accès à Amazon Redshift, si vous spécifiez un chemin d'inclusion `MyDatabase/%`, toutes les tables de tous les schémas de la base de données `MyDatabase` sont créées dans Data Catalog. Si vous spécifiez un chemin d'inclusion `MyDatabase/MySchema/%`, toutes les tables de la base de données `MyDatabase` et du schéma `MySchema` sont créées.

Après que vous avez spécifié un chemin d'inclusion, vous pouvez exclure les objets de l'analyse qui sinon seraient inclus dans votre chemin d'inclusion en spécifiant un ou plusieurs modèles d'exclusion glob de style Unix. Ces modèles sont appliqués à votre chemin d'inclusion afin de déterminer les objets exclus. Ces modèles sont également stockés comme propriété de tables créées par l'analyseur. AWS Glue PySpark les extensions, telles que `create_dynamic_frame.from_catalog`, lisent les propriétés de la table et excluent les objets définis par le modèle d'exclusion.

AWS Glue prend en charge les glob modèles suivants dans le modèle d'exclusion.

Modèle d'exclusion	Description
<code>*.csv</code>	Correspond à un chemin Amazon S3 qui représente un nom d'objet se terminant par <code>.csv</code> dans le dossier actuel
<code>*.*</code>	Correspond à tous les noms d'objets qui contiennent un point
<code>*.{csv,avro}</code>	Correspond aux noms d'objets se terminant par <code>.csv</code> ou <code>.avro</code>
<code>foo.?</code>	Correspond aux noms d'objets commençant par <code>foo.</code> et suivis par une extension d'un seul caractère

Modèle d'exclusion	Description
<code>myfolder/*</code>	Correspond aux objets situés un niveau en dessous du sous-dossier <code>myfolder</code> , comme <code>/myfolder/mysource</code>
<code>myfolder/*/*</code>	Correspond aux objets situés deux niveaux en dessous du sous-dossier <code>myfolder</code> , comme <code>/myfolder/mysource/data</code>
<code>myfolder/**</code>	Correspond aux objets situés dans tous les sous-dossiers de <code>myfolder</code> , comme <code>/myfolder/mysource/mydata</code> et <code>/myfolder/mysource/data</code>
<code>myfolder**</code>	Correspond au sous-dossier <code>myfolder</code> , ainsi qu'aux fichiers sous <code>myfolder</code> , tels que <code>/myfolder</code> et <code>/myfolder/mydata.txt</code>
<code>Market*</code>	Correspond aux tables d'une base de données JDBC dont les noms commencent par <code>Market</code> , comme <code>Market_us</code> et <code>Market_fr</code>

AWS Glue interprète les modèles glob d'exclusion comme suit :

- La barre oblique (/) est le délimiteur qui permet de séparer les clés Amazon S3 dans une hiérarchie de dossiers.
- L'astérisque (*) correspond à zéro ou plusieurs caractères d'un composant de nom sans dépasser les limites d'un dossier.
- Deux astérisques (**) correspondent à zéro ou plusieurs caractères dépassant les limites d'un dossier ou d'un schéma.
- Le point d'interrogation (?) correspond exactement à un caractère d'un composant de nom.
- La barre oblique inverse (\) est utilisée pour échapper des caractères qui seraient sinon interprétés comme des caractères spéciaux. L'expression `\\` correspond à une barre oblique inverse, et `\{` correspond à une accolade gauche.

- Les crochets [] créent une expression entre crochets qui correspond à un caractère unique d'un composant de nom dans un ensemble de caractères. Par exemple, [abc] correspond à a, b ou c. Le trait d'union (-) peut être utilisé pour spécifier une plage ; [a-z] spécifie une plage allant de a à z (inclus). Ces formulaires peuvent être mélangés ; [abce-g] correspond à a, b, c, e, f ou g. Si le caractère placé après le crochet ([]) est un point d'exclamation (!), l'expression entre crochets est inversée. Par exemple, [!a-c] correspond à un caractère quelconque, à l'exception de a, b ou c.

Dans une expression entre crochets, les caractères *, ? et \ correspondent à eux-mêmes. Le trait d'union (-) correspond à lui-même lorsqu'il est placé en première position entre les crochets, ou s'il est le premier caractère placé après le point d'exclamation ! lors d'une inversion.

- Les accolades ({ }) entourent un groupe de sous-modèles, où le groupe correspond si un des sous-modèles du groupe correspond. La virgule (,) est utilisée pour séparer les sous-modèles. Les groupes ne peuvent pas être imbriqués.
- Une virgule ou un point placé au début d'un nom de fichier est traité comme un caractère normal dans les opérations de correspondance. Par exemple, le modèle d'exclusion * correspond au nom de fichier .hidden.

Exemple Modèles d'exclusion Amazon S3

Chaque modèle d'exclusion est évalué par rapport au chemin d'inclusion. Par exemple, supposons que vous disposiez de la structure de répertoires Amazon S3 suivante :

```
/mybucket/myfolder/  
  departments/  
    finance.json  
    market-us.json  
    market-emea.json  
    market-ap.json  
  employees/  
    hr.json  
    john.csv  
    jane.csv  
    juan.txt
```

Soit le chemin d'inclusion s3://mybucket/myfolder/, voici quelques exemples de résultats pour les chemins d'exclusion :

Modèle d'exclusion	Résultats
<code>departments/**</code>	Exclut tous les fichiers et dossiers sous <code>departments</code> et inclut le dossier <code>employees</code> et ses fichiers
<code>departments/market*</code>	Exclut <code>market-us.json</code> , <code>market-em</code> <code>ea.json</code> et <code>market-ap.json</code>
<code>** .csv</code>	Exclut tous les objets sous <code>myfolder</code> dont le nom se termine par <code>.csv</code>
<code>employees/*.csv</code>	Exclut tous les fichiers <code>.csv</code> du dossier <code>employees</code>

Exemple Exclusion d'un sous-ensemble de partitions Amazon S3

Supposons que vos données soient partitionnées par jour, de telle sorte que chaque jour d'une année se trouve dans une partition Amazon S3 distincte. Pour le mois de janvier 2015, il y a 31 partitions. Maintenant, pour analyser uniquement les données de la première semaine de janvier, vous devez exclure toutes les partitions, à l'exception des jours 1 à 7 :

```
2015/01/{[!0],0[8-9]}**, 2015/0[2-9]**, 2015/1[0-2]**
```

Examinons les différentes parties de ce modèle glob. La première partie, `2015/01/{[!0],0[8-9]}**`, exclut tous les jours qui ne commencent pas par un « 0 », ainsi que le jour 08 et le jour 09 du mois 01 de l'année 2015. Notez que « `**` » est utilisé comme suffixe du modèle de numéro du jour et dépasse les limites de dossier vers les dossiers de niveau inférieur. Si « `*` » est utilisé, les dossiers de niveau inférieur ne sont pas exclus.

La deuxième partie, `2015/0[2-9]**`, exclut les jours des mois 02 à 09 de l'année 2015.

La troisième partie, `2015/1[0-2]**`, exclut les jours des mois 10, 11 et 12 de l'année 2015.

Exemple Modèles d'exclusion JDBC

Supposons que vous analysiez une base de données JDBC avec la structure de schéma suivante :

```
MyDatabase/MySchema/  
  HR_us  
  HR_fr  
  Employees_Table  
  Finance  
  Market_US_Table  
  Market_EMEA_Table  
  Market_AP_Table
```

Soit le chemin d'inclusion MyDatabase/MySchema/%, voici quelques exemples de résultats pour les chemins d'exclusion :

Modèle d'exclusion	Résultats
HR*	Exclut les tables dont le nom commence par HR
Market_*	Exclut les tables dont le nom commence par Market_
**_Table	Exclut toutes les tables dont le nom se termine par _Table

Paramètres de source d'crawler supplémentaires

Chaque type de source requiert un jeu différent de paramètres supplémentaires.

Connexion

Sélectionnez ou ajoutez un AWS Glue connexion. Pour obtenir des informations sur les connexions, consultez [Connexion aux données](#).

Métadonnées supplémentaires : facultatives (pour les magasins de données JDBC)

Sélectionnez des propriétés de métadonnées supplémentaires à analyser par le crawler.

- Commentaires : analysez des commentaires associés au niveau de la table et au niveau de la colonne.
- Types bruts : conservez les types de données bruts des colonnes de la table dans les métadonnées supplémentaires. Par défaut, le crawler traduit les types de données bruts en types compatibles avec Hive.

Nom de la classe de pilote JDBC – facultatif (pour les magasins de données JDBC)

Saisissez un nom de classe de pilote JDBC personnalisé pour que le Crawler se connecte à la source de données :

- Postgres : `org.postgresql.Driver`
- MySQL : `com.mysql.jdbc.Driver`, `com.mysql.cj.jdbc.Driver`
- Redshift : `com.amazon.redshift.jdbc.Driver`, `com.amazon.redshift.jdbc42.Driver`
- Oracle : `oracle.jdbc.driver.OracleDriver`
- Serveur SQL : `com.microsoft.sqlserver.jdbc.SQLServerDriver`

Chemin S3 du pilote JDBC – facultatif (pour les magasins de données JDBC)

Choisissez un chemin Amazon S3 existant vers un fichier `.jar`. C'est là que le fichier `.jar` est stocké lorsque vous utilisez un pilote JDBC personnalisé pour que le Crawler se connecte à la source de données.

Activer l'échantillonnage de données (pour les magasins de données Amazon DynamoDB, MongoDB, MongoDB Atlas et Amazon DocumentDB uniquement)

Indiquez si vous souhaitez analyser un échantillon de données uniquement. Si ce n'est pas sélectionné, la table entière est analysée. L'analyse de tous les enregistrements peut prendre beaucoup de temps lorsque la table n'est pas à haut débit.

Créer des tables pour les requêtes (uniquement pour les magasins de données Delta Lake)

Sélectionnez la façon dont vous souhaitez créer les tables Delta Lake :

- Créer des tables natives : permettre l'intégration avec les moteurs de requêtes qui prennent directement en charge l'interrogation du journal de transactions Delta.
- Créer des tables avec des liens symboliques : créer un dossier manifeste de lien symbolique avec les fichiers manifestes partitionnés par les clés de partition, en fonction des paramètres de configuration spécifiés.

Taux d'analyse : facultatif (pour les magasins de données DynamoDB uniquement)

Spécifiez le pourcentage des unités de capacité de lecture de la table DynamoDB à utiliser par le crawler. Unités de capacité de lecture est un terme défini par DynamoDB et est une valeur numérique qui sert de limiteur de vitesse pour le nombre de lectures pouvant être effectuées sur cette table par seconde. Saisissez une valeur comprise entre 0,1 et $1.5^{63} - 1$. Si ce n'est pas spécifié, la valeur par défaut est 0,5 pour les tables provisionnées et 1/4 de la capacité maximale configurée pour les tables à la demande. Notez que seul le mode de capacité provisionnée doit être utilisé avec les AWS Glue robots d'exploration.

Note

Pour les magasins de données DynamoDB, définissez le mode de capacité provisionnée pour traiter les lectures et écritures dans vos tables. Le AWS Glue robot ne doit pas être utilisé avec le mode de capacité à la demande.

Connexion réseau : en option (pour les magasins de données cibles Amazon S3, Delta, Iceberg, Hudi et Catalog)

Vous pouvez également inclure une connexion réseau à utiliser avec cette cible Amazon S3. Notez que chaque crawler est limité à une connexion réseau et toutes les autres cibles Amazon S3 utilisent la même connexion (ou aucune, si ce champ est laissé vide).

Pour obtenir des informations sur les connexions, consultez [Connexion aux données](#).

Échantillon portant sur un seul sous-ensemble de fichiers et taille de l'échantillon (pour les magasins de données Amazon S3 uniquement)

Spécifiez le nombre de fichiers dans chaque dossier feuille à analyser lors de l'analyse d'échantillons de fichiers dans un jeu de données. Lorsque cette fonction est activée, au lieu d'analyser tous les fichiers de ce jeu de données, l'crawler sélectionne au hasard certains fichiers dans chaque dossier feuille à analyser.

Le crawler d'échantillonnage est le mieux adapté aux clients qui ont des connaissances préalables sur leurs formats de données et savent que les schémas de leurs dossiers ne changent pas. L'activation de cette fonction réduira considérablement le temps d'exécution de l'crawler.

Une valeur valide est un entier compris entre 1 et 249. Si ce n'est pas spécifié, tous les fichiers sont analysés.

Exécutions ultérieures du crawler

Ce champ est un champ global qui concerne toutes les sources de données Amazon S3.

- Analyser tous les sous-dossiers : analyser à nouveau tous les dossiers à chaque analyse suivante.
- Analyser uniquement les nouveaux sous-dossiers : seuls les dossiers Amazon S3 ajoutés depuis la dernière analyse sont analysés. Si les schémas sont compatibles, de nouvelles partitions sont ajoutées aux tables existantes. Pour plus d'informations, consultez [the section called "Planification d'analyses incrémentielles"](#).
- Analyse basée sur les événements : utiliser les événements Amazon S3 pour contrôler les dossiers à analyser. Pour de plus amples informations, veuillez consulter [Accélération des analyseurs à l'aide des notifications d'événements Amazon S3](#).

Classifieurs personnalisés - facultatif

Définissez des classifieurs personnalisés avant de définir des crawlers. Un classifieur vérifie si un fichier donné est dans un format que le crawler peut gérer. Si c'est le cas, le classifieur crée un schéma sous la forme d'un objet StructType correspondant à ce format de données.

Pour de plus amples informations, veuillez consulter [Définition et gestion des classificateurs](#).

Étape 3 : Configurer les paramètres de sécurité

Rôle IAM

L'crawler endosse ce rôle. Il doit disposer d'autorisations similaires à celles de la politique AWS gérée `AWSGlueServiceRole`. Pour les sources Amazon S3 et DynamoDB, il doit également disposer des autorisations pour accéder au magasin de données. Si le robot lit les données Amazon S3 chiffrées avec AWS Key Management Service (AWS KMS), le rôle doit disposer d'autorisations de déchiffrement sur la AWS KMS clé.

Pour un magasin de données Amazon S3, les autorisations supplémentaires attachées au rôle seraient similaires à ce qui suit :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
```

```

        "Action": [
            "s3:GetObject",
            "s3:PutObject"
        ],
        "Resource": [
            "arn:aws:s3::bucket/object*"
        ]
    }
]
}

```

Pour un magasin de données Amazon DynamoDB, les autorisations supplémentaires attachées au rôle seraient similaires à ce qui suit :

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "dynamodb:DescribeTable",
        "dynamodb:Scan"
      ],
      "Resource": [
        "arn:aws:dynamodb:region:account-id:table/table-name*"
      ]
    }
  ]
}

```

Pour ajouter votre propre pilote JDBC, des autorisations supplémentaires doivent être ajoutées.

- Accordez des autorisations pour les actions de tâches suivantes : CreateJob, DeleteJob, GetJob, GetJobRun, StartJobRun.
- Accordez des autorisations pour les actions Amazon S3 : s3:DeleteObjects, s3:GetObject, s3:ListBucket, s3:PutObject.

Note

Le s3:ListBucket n'est pas nécessaire si la stratégie de compartiment Amazon S3 est désactivée.

- Accordez au principal de service l'accès au compartiment ou au dossier dans la stratégie Amazon S3.

Exemple de stratégie Amazon S3 :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "VisualEditor0",
      "Effect": "Allow",
      "Action": [
        "s3:PutObject",
        "s3:GetObject",
        "s3:ListBucket",
        "s3:DeleteObject"
      ],
      "Resource": [
        "arn:aws:s3:::bucket-name/driver-parent-folder/driver.jar",
        "arn:aws:s3:::bucket-name"
      ]
    }
  ]
}
```

AWS Glue crée les dossiers suivants (`_crawler` et `_glue_job_crawler` au même niveau que le pilote JDBC) dans votre compartiment Amazon S3. Par exemple, si le chemin du pilote est `<s3-path/driver_folder/driver.jar>`, les dossiers suivants seront créés s'ils n'existent pas déjà :

- `<s3-path/driver_folder/_crawler>`
- `<s3-path/driver_folder/_glue_job_crawler>`

Le cas échéant, vous pouvez ajouter une configuration de sécurité à un crawler pour spécifier les options de chiffrement au repos.

Pour plus d'informations, consultez [Étape 2 : créer un rôle IAM pour AWS Glue](#) et [Gestion des identités et des accès pour AWS Glue](#).

Configuration de Lake Formation - Facultatif

Autorisez le crawler à utiliser les informations d'identification de Lake Formation pour analyser la source de données.

Si vous cochez la case Utiliser les informations d'identification Lake Formation pour analyser la source de données S3, le crawler peut utiliser les informations d'identification Lake Formation pour analyser la source de données. Si la source de données appartient à un autre compte, vous devez fournir l'ID de compte enregistré. À défaut, le crawler n'analysera que les sources de données associées au compte. Applicable uniquement aux sources de données Amazon S3 et Data Catalog.

Configuration de sécurité - Facultatif

Les paramètres incluent les configurations de sécurité. Pour plus d'informations, consultez les ressources suivantes :

- [Chiffrement de données écrites par AWS Glue](#)

Note

Une fois qu'une configuration de sécurité a été définie sur un robot d'exploration, vous pouvez la modifier, mais vous ne pouvez pas la supprimer. Pour réduire le niveau de sécurité d'un robot d'exploration, définissez explicitement la fonctionnalité de sécurité DISABLED dans votre configuration ou créez un nouveau robot d'exploration.

Étape 4 : Configurer la sortie et la planification

Configuration de la sortie

Les options incluent la façon dont le crawler doit gérer des modifications de schéma, les objets supprimés détectés dans le magasin de données, et plus encore. Pour plus d'informations, consultez [Personnalisation du comportement des robots d'exploration](#).

Planificateur d'crawler

Vous pouvez exécuter un crawler à la demande ou définir une planification temporelle pour vos crawlers et vos tâches dans AWS Glue. La définition de ces planifications utilise la syntaxe de type Unix cron. Pour de plus amples informations, veuillez consulter [Planification d'un crawler](#).

Étape 5 : Vérification et création

Passez en revue les paramètres du crawler que vous avez configurés et créez le crawler.

Planification d'un crawler

Vous pouvez exécuter un AWS Glue crawler à la demande ou selon un planning régulier. Lorsque vous configurez un robot sur la base d'un calendrier, vous pouvez définir certaines contraintes, telles que la fréquence d'exécution du robot, les jours de la semaine où il s'exécute et à quelle heure. Vous pouvez créer ces plannings personnalisés au format cron. Pour plus d'informations, consultez [cron](#) dans Wikipedia.

Lorsque vous configurez une planification d'crawler, prenez en compte les fonctions et limitations de cron. Par exemple, si vous choisissez d'exécuter votre crawler le 31 de chaque mois, n'oubliez pas que certains mois ne comportent pas 31 jours.

Rubriques

- [Création d'un calendrier pour les robots d'exploration](#)
- [Création d'un calendrier pour un robot d'exploration existant](#)

Création d'un calendrier pour les robots d'exploration

Vous pouvez créer un calendrier pour le robot d'exploration à l'aide de la AWS Glue console ou AWS CLI.

AWS Management Console

1. Connectez-vous au AWS Management Console, puis ouvrez le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Sélectionnez Crawlers dans le panneau de navigation.
3. Suivez les étapes 1 à 3 de la [Configuration d'un crawler](#) section.
4. Dans [Étape 4 : Configurer la sortie et la planification](#), choisissez un calendrier Crawler pour définir la fréquence de l'exécution. Vous pouvez choisir que le robot soit exécuté toutes les heures, tous les jours, toutes les semaines, tous les mois ou définir un calendrier personnalisé à l'aide d'expressions cron.

Une expression cron est une chaîne représentant un modèle de planification, composée de 6 champs séparés par des espaces : * * * * * <minute><hour><day of month><month><day of week><year>

Par exemple, pour exécuter une tâche tous les jours à minuit, l'expression cron est : 0 0 * * ? *

Pour plus d'informations, consultez la section [Expressions Cron](#).

5. Passez en revue les paramètres du robot d'exploration que vous avez configurés et créez le robot de recherche pour qu'il s'exécute selon un calendrier.

AWS CLI

```
aws glue create-crawler
--name myCrawler \
--role AWSGlueServiceRole-myCrawler \
--targets '{"S3Targets":[{"Path":"s3://amzn-s3-demo-bucket/"}]}' \
--schedule cron(15 12 * * ? *)
```

Pour plus d'informations sur l'utilisation de cron pour planifier les tâches et les crawlers, reportez-vous à la section [Planifications temporelles pour les tâches et les crawlers](#).

Création d'un calendrier pour un robot d'exploration existant

Suivez ces étapes pour configurer un calendrier récurrent pour un robot d'exploration existant.

AWS Management Console

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Sélectionnez Crawlers dans le panneau de navigation.
3. Choisissez un robot d'exploration que vous souhaitez planifier dans la liste disponible.
4. Choisissez Modifier dans le menu Actions.
5. Faites défiler la page jusqu'à l'étape 4 : définir la sortie et la planification, puis choisissez Modifier.
6. Mettez à jour le planning de votre crawler sous le planning du crawler.
7. Choisissez Mettre à jour.

AWS CLI

Utilisez la commande CLI suivante pour mettre à jour la configuration d'un crawler existant :

```
aws glue update-crawler-schedule
  --crawler-name myCrawler
  --schedule cron(15 12 * * ? *)
```

Affichage des résultats et des détails du crawler

Une fois que l'crawler s'exécute correctement, il crée des définitions de table dans Data Catalog. Sélectionnez Tables dans le panneau de navigation pour afficher les tables créées par votre crawler dans la base de données que vous avez spécifiée.

Vous pouvez afficher les informations relatives à l'crawler lui-même comme suit :

- La page Crawlers de la AWS Glue console affiche les propriétés suivantes d'un robot d'exploration :

Propriété	Description
Nom	Lorsque vous créez un crawler, vous devez lui attribuer un nom unique.
Statut	Un crawler peut être prêt, en cours de démarrage, en cours d'arrêt, planifié ou suspendu par le calendrier. Un crawler en cours d'exécution progresse du démarrage à l'arrêt. Vous pouvez reprendre ou suspendre un calendrier attaché à un crawler.
Schedule	Vous pouvez choisir d'exécuter votre crawler à la demande ou choisir une fréquence avec un calendrier. Pour plus d'informations sur la planification d'un crawler, consultez Planification d'un crawler .

Propriété	Description
Dernière exécution	Date et heure de la dernière exécution du crawler.
Journal	Liens vers les journaux disponibles depuis la dernière exécution de l'crawler.
Modifications apportées aux tables depuis la dernière exécution	Le nombre de tables du AWS Glue Data Catalog qui ont été mises à jour lors de la dernière exécution du robot d'exploration.

- Pour afficher l'historique d'un crawler, choisissez Crawlers dans le panneau de navigation pour voir les crawlers que vous avez créés. Choisissez un crawler dans la liste des crawlers disponibles. Vous pouvez consulter les propriétés du crawler et consulter l'historique du crawler dans l'onglet Crawler runs (Exécutions du crawler).

L'onglet Crawler s'exécute affiche des informations sur chaque exécution du crawler, notamment l'heure de début (UTC), l'heure de fin (UTC), la durée, l'état, les heures DPU, et les modifications apportées aux tables.

L'onglet Exécutions du Crawler affiche uniquement les analyses qui ont eu lieu depuis la date de lancement de la fonction d'historique du Crawler et ne retient que jusqu'à 12 mois d'analyse. Les anciennes analyses ne seront pas renvoyées.

- Pour voir des informations supplémentaires, choisissez un onglet sur la page de détails du crawler. Chaque onglet affiche les informations relatives au crawler.
 - Schedule (Programme) : tous les programmes créés pour le crawler seront visibles ici.
 - Data sources (Sources de données) : toutes les sources de données analysées par le crawler seront visibles ici.
 - Classifiers (Classifieurs) : tous les classifieurs assignés au crawler seront visibles ici.
 - Balises : toutes les balises créées et attribuées à une AWS ressource seront visibles ici.

Paramètres définis sur les tables du Catalogue de données par un Crawler

Ces propriétés de table sont définies par les AWS Glue robots d'exploration. Nous nous attendons à ce que les utilisateurs consomment les propriétés `classification` et `compressionType`. D'autres propriétés, dont les estimations de la taille des tables, sont utilisées pour les calculs

internes, et nous ne garantissons pas leur exactitude ou leur applicabilité aux cas d'utilisation des clients. La modification de ces paramètres peut modifier le comportement du Crawler. Nous ne prenons pas en charge ce flux.

Clé de propriété	Valeur de la propriété
UPDATED_BY_CRAWLER	Nom du Crawler qui effectue la mise à jour.
connectionName	Nom de la connexion dans le catalogue de données pour le crawler utilisé pour se connecter au magasin de données.
recordCount	Estimation du nombre d'enregistrements dans la table, basée sur la taille des fichiers et des en-têtes.
skip.header.line.count	Lignes ignorées pour ignorer l'en-tête. Définie sur des tables classées au format CSV.
CrawlerSchemaSerializerVersion	Pour utilisation interne
classification	Format des données, déduit par le Crawler. Pour plus d'informations sur les formats de données pris en charge par les AWS Glue robots d'exploration, consultez the section called “Classificateurs intégrés” .
CrawlerSchemaDeserializerVersion	Pour utilisation interne
sizeKey	Taille combinée des fichiers dans la table indexée.
averageRecordSize	Taille moyenne des lignes dans la table, en octets.
compressionType	Type de compression utilisé sur les données de la table. Pour plus d'informations sur les types de compression pris en charge par les AWS Glue robots d'exploration, consultez the section called “Classificateurs intégrés” .

Clé de propriété	Valeur de la propriété
<code>typeOfData</code>	<code>file</code> , <code>table</code> ou <code>view</code> .
<code>objectCount</code>	Nombre d'objets sous le chemin Amazon S3 pour la table.

Ces propriétés de table supplémentaires sont définies par les robots d' AWS Glue exploration pour les magasins de données Snowflake.

Clé de propriété	Valeur de la propriété
<code>aws:RawTableLastAltered</code>	Enregistre le dernier horodatage modifié de la table Snowflake.
<code>ViewOriginalText</code>	Affichez l'instruction SQL.
<code>ViewExpandedText</code>	Affichez l'instruction SQL codée au format Base64.
<code>ExternalTable:S3Location</code>	Emplacement Amazon S3 de la table externe Snowflake.
<code>ExternalTable:FileFormat</code>	Format de fichier Amazon S3 de la table externe Snowflake.

Ces propriétés de table supplémentaires sont définies par des robots d' AWS Glue exploration pour les magasins de données de type JDBC tels qu'Amazon Redshift, Microsoft SQL Server, MySQL, PostgreSQL et Oracle.

Clé de propriété	Valeur de la propriété
<code>aws:RawType</code>	Lorsqu'un crawler stocke les données dans le catalogue de données, il traduit les types de données en types compatibles avec Hive, ce qui entraîne souvent la perte des informations relatives au type de données

Clé de propriété	Valeur de la propriété
	natif. Le crawler génère le paramètre <code>aws:RawType</code> pour fournir le type de données de niveau natif.
<code>aws:RawColumnComment</code>	Si un commentaire est associé à une colonne de la base de données, le crawler génère le commentaire correspondant dans la table du catalogue. La chaîne de commentaire est tronquée à 255 octets. Les commentaires ne sont pas pris en charge pour Microsoft SQL Server.
<code>aws:RawTableComment</code>	Si un commentaire est associé à une table de la base de données, le crawler génère le commentaire correspondant dans la table du catalogue. La chaîne de commentaire est tronquée à 255 octets. Les commentaires ne sont pas pris en charge pour Microsoft SQL Server.

Personnalisation du comportement des robots d'exploration

Lorsque vous configurez un AWS Glue crawler, vous disposez de plusieurs options pour définir le comportement de votre robot d'exploration.

- **Analyses incrémentielles** : vous pouvez configurer un explorateur pour exécuter des analyses incrémentielles afin d'ajouter uniquement de nouvelles partitions au schéma de table.
- **Index de partition** : un robot d'exploration crée des index de partition pour les cibles Amazon S3 et Delta Lake par défaut afin de permettre une recherche efficace de partitions spécifiques.
- **Accélérez le temps d'exploration en utilisant les événements Amazon S3** : vous pouvez configurer un robot pour qu'il utilise les événements Amazon S3 afin d'identifier les changements entre deux analyses en listant tous les fichiers du sous-dossier qui a déclenché l'événement au lieu de répertorier la cible complète d'Amazon S3 ou du catalogue de données.
- **Gestion des modifications de schéma** — Vous pouvez empêcher un robot d'exploration d'apporter des modifications au schéma existant. Vous pouvez utiliser le AWS Management Console ou le AWS Glue API pour configurer la manière dont votre robot traite certains types de modifications.

- Un schéma unique pour plusieurs chemins Amazon S3 : vous pouvez configurer un robot d'exploration pour créer un schéma unique pour chaque chemin S3 si les données sont compatibles.
- Emplacement des tables et niveaux de partitionnement : l'option d'exploration au niveau des tables vous permet d'indiquer à l'analyseur où se trouvent les tables et comment vous souhaitez créer les partitions.
- Seuil de table — Vous pouvez spécifier le nombre maximum de tables que le robot d'exploration est autorisé à créer en spécifiant un seuil de table.
- AWS Lake Formation informations d'identification — Vous pouvez configurer un robot d'exploration pour qu'il utilise les informations d'identification de Lake Formation pour accéder à un magasin de données Amazon S3 ou à une table du catalogue de données avec un emplacement Amazon S3 sous-jacent au même emplacement Compte AWS ou à un autre Compte AWS.

Pour plus d'informations sur l'utilisation du AWS Glue console pour ajouter un robot d'exploration, voir [Configuration d'un crawler](#).

Rubriques

- [Planification d'analyses incrémentielles pour ajouter de nouvelles partitions](#)
- [Génération d'index de partition](#)
- [Empêcher un robot d'exploration de modifier un schéma existant](#)
- [Création d'un schéma unique pour chaque chemin d'inclusion Amazon S3](#)
- [Spécification de l'emplacement de la table et du niveau de partitionnement](#)
- [Spécifier le nombre maximum de tables que le robot d'exploration est autorisé à créer](#)
- [Configuration d'un robot d'exploration pour utiliser les informations d'identification de Lake Formation](#)
- [Accélération des analyseurs à l'aide des notifications d'événements Amazon S3](#)

Planification d'analyses incrémentielles pour ajouter de nouvelles partitions


Vous pouvez configurer et AWS Glue crawler exécuter des analyses incrémentielles pour ajouter uniquement de nouvelles partitions au schéma de table. Lorsque le robot s'exécute pour la première fois, il effectue une analyse complète pour traiter l'intégralité de la source de données afin d'enregistrer le schéma complet et toutes les partitions existantes dans le. AWS Glue Data Catalog

Les analyses suivantes après l'analyse complète initiale seront incrémentielles, le robot identifiant et ajoutant uniquement les nouvelles partitions introduites depuis l'analyse précédente. Cette approche permet d'accélérer les temps d'exploration, car le robot d'exploration n'a plus besoin de traiter l'intégralité de la source de données à chaque exécution, mais se concentre uniquement sur les nouvelles partitions.

Note

Les analyses incrémentielles ne détectent pas les modifications ou les suppressions de partitions existantes. Cette configuration convient parfaitement aux sources de données dotées d'un schéma stable. En cas de modification majeure ponctuelle du schéma, il est conseillé de configurer temporairement le robot d'exploration pour qu'il effectue une analyse complète afin de capturer le nouveau schéma avec précision, puis de revenir en mode d'analyse incrémentielle.

Le schéma suivant montre que lorsque le paramètre d'analyse incrémentielle est activé, le robot détecte et ajoute uniquement le dossier nouvellement ajouté, MONTH=March, au catalogue.



Procédez comme suit pour mettre à jour votre robot afin d'effectuer des analyses incrémentielles :

AWS Management Console

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez Crawlers dans le catalogue de données.

3. Choisissez un robot d'exploration que vous souhaitez configurer pour qu'il explore de manière incrémentielle.
4. Choisissez Modifier.
5. Choisissez l'étape 2. Choisissez les sources de données et les classificateurs.
6. Choisissez la source de données que vous souhaitez analyser de manière incrémentielle.
7. Choisissez Modifier.
8. Choisissez Analyser les nouveaux sous-dossiers uniquement sous Exécutions d'exploration ultérieures.
9. Choisissez Mettre à jour.

Pour créer un calendrier pour un robot d'exploration, consultez [the section called “Planification d'un crawler”](#).

AWS CLI

```
aws glue update-crawler \  
  --name myCrawler \  
  --recrawl-policy RecrawlBehavior=CRAWL_NEW_FOLDERS_ONLY \  
  --schema-change-policy UpdateBehavior=LOG,DeleteBehavior=LOG
```

Notes et restrictions

Lorsque cette option est activée, vous ne pouvez pas modifier les magasins de données cibles Amazon S3 lors de la modification de l'crawler. Cette option affecte certains paramètres de configuration de l'crawler. Lorsqu'il est activé, il force le comportement de mise à jour et le comportement de suppression de l'crawler à LOG. Cela signifie que :

- S'il découvre des objets dont les schémas ne sont pas compatibles, le robot d'exploration n'ajoutera pas les objets dans le catalogue de données et ajoute ce détail sous forme de journal de connexion. CloudWatch
- Il ne met pas à jour les objets supprimés dans le catalogue de données.

Génération d'index de partition

Le catalogue de données prend en charge la création d'index de partition afin de permettre une recherche efficace de partitions spécifiques. Pour plus d'informations, consultez la section [Création](#)

[d'index de partition](#). Le AWS Glue crawler crée des index de partition pour les cibles Amazon S3 et Delta Lake par défaut.

AWS Management Console

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez Crawlers dans le catalogue de données.
3. Lorsque vous définissez un robot d'exploration, l'option permettant de créer automatiquement des index de partition est activée par défaut sous Options avancées de la page Définir la sortie et la planification.

Pour désactiver cette option, vous pouvez décocher la case Créer des index de partition automatiquement dans la console.

4. Complétez la configuration du robot d'exploration et choisissez Create crawler.

AWS CLI

Vous pouvez également désactiver cette option en utilisant le configuration paramètre AWS CLI, définissez le. `CreatePartitionIndex` La valeur par défaut est `True`.

```
aws glue update-crawler \  
  --name myCrawler \  
  --configuration '{"Version": 1.0, "CreatePartitionIndex": false }'
```

Notes d'utilisation pour les index de partition

- Les tables créées par le Crawler ne contiennent pas la variable `partition_filtering.enabled` par défaut. Pour en savoir plus, consultez [AWS Glue partition indexing and filtering](#).
- La création d'index de partition pour les partitions chiffrées n'est pas prise en charge.

Empêcher un robot d'exploration de modifier un schéma existant

Vous pouvez empêcher AWS Glue crawler s d'apporter des modifications de schéma au catalogue de données lors de son exécution. Par défaut, les robots mettent à jour le schéma du catalogue de données pour qu'il corresponde à la source de données analysée. Toutefois, dans certains cas, vous

souhaiterez peut-être empêcher le Crawler de modifier le schéma existant, en particulier si vous avez transformé ou nettoyé les données et que vous ne souhaitez pas que le schéma d'origine remplace les modifications.

Suivez ces étapes pour configurer votre robot de manière à ne pas remplacer le schéma existant dans une définition de table.

AWS Management Console

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez Crawlers dans le catalogue de données.
3. Choisissez un robot dans la liste, puis cliquez sur Modifier.
4. Choisissez l'étape 4, Définir la sortie et la planification.
5. Sous Options avancées, choisissez Ajouter de nouvelles colonnes uniquement ou Ignorer la modification et ne pas mettre à jour le tableau dans le catalogue de données.
6. Vous pouvez également définir une option de configuration pour mettre à jour toutes les partitions nouvelles et existantes avec les métadonnées de la table. Cela définit les schémas de partition pour qu'ils héritent de la table.
7. Choisissez Mettre à jour.

AWS CLI

L'exemple suivant montre comment configurer un robot de recherche pour ne pas modifier le schéma existant, mais uniquement pour ajouter de nouvelles colonnes :

```
aws glue update-crawler \  
  --name myCrawler \  
  --configuration '{"Version": 1.0, "CrawlerOutput": {"Tables":  
    {"AddOrUpdateBehavior": "MergeNewColumns"}}}'
```

L'exemple suivant montre comment configurer un robot de recherche pour ne pas modifier le schéma existant et pour ne pas ajouter de nouvelles colonnes :

```
aws glue update-crawler \  
  --name myCrawler \  
  --configuration '{"Version": 1.0, "CrawlerOutput": {"Tables":  
    {"AddOrUpdateBehavior": "IgnoreModification"}}}'
```



```
--schema-change-policy UpdateBehavior=LOG \  
--configuration '{"Version": 1.0, "CrawlerOutput": {"Partitions":  
{ "AddOrUpdateBehavior": "InheritFromTable" }}}'
```

API

Si vous ne voulez pas qu'un schéma de table soit modifié lorsqu'un crawler s'exécute, définissez la politique de modification du schéma sur LOG.

Lorsque vous configurez le crawler à l'aide de l'API, définissez les paramètres suivants :

- Définissez le champ `UpdateBehavior` de la structure `SchemaChangePolicy` sur LOG.
- Définissez le champ `Configuration` avec une représentation de chaîne de l'objet JSON suivant dans l'API de l'API de l'API ; par exemple :

```
{  
  "Version": 1.0,  
  "CrawlerOutput": {  
    "Partitions": { "AddOrUpdateBehavior": "InheritFromTable" }  
  }  
}
```

Création d'un schéma unique pour chaque chemin d'inclusion Amazon S3

Par défaut, lorsqu'un crawler définit des tables pour des données stockées dans Amazon S3, il prend en compte la compatibilité des données et la similitude de schéma. Parmi les facteurs de compatibilité des données, il prend en compte le fait que les données sont du même format (par exemple, JSON), le même type de compression (par exemple, GZIP), la structure du chemin d'accès Amazon S3 et d'autres caractéristiques de données. La similarité des schémas définit le degré de similarité des schémas d'objets Amazon S3 distincts.

Pour vous aider à illustrer cette option, supposons que vous définissez un crawler avec un chemin d'inclusion `s3://amzn-s3-demo-bucket/table1/`. Lorsque le crawler s'exécute, il trouve deux fichiers JSON avec les caractéristiques suivantes :

- Fichier 1 – `S3://amzn-s3-demo-bucket/table1/year=2017/data1.json`
- Contenu du fichier – `{"A": 1, "B": 2}`
- Schéma – `A:int, B:int`

- Fichier 2 – S3://amzn-s3-demo-bucket/table1/year=2018/data2.json
- Contenu du fichier – {"C": 3, "D": 4}
- Schéma – C: int, D: int

Par défaut, l'crawler crée deux tables, nommées `year_2017` et `year_2018` car les schémas ne sont pas suffisamment similaires. Toutefois, si l'option `Create a single schema for each S3 path` (Créer un seul schéma pour chaque chemin S3) est sélectionnée, et si les données sont compatibles, l'crawler crée une table. La table comprend le schéma `A:int,B:int,C:int,D:int` et `partitionKey year:string`.

AWS Management Console

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez Crawlers dans le catalogue de données.
3. Lorsque vous configurez un nouveau robot, sous Sortie et planification, sélectionnez l'option Créer un schéma unique pour chaque chemin S3 sous Options avancées.

AWS CLI

Vous pouvez configurer un crawler pour `CombineCompatibleSchemas` dans une définition de table courante lorsque cela est possible. Avec cette option, l'crawler considère toujours la compatibilité des données, mais ignore la similarité des schémas spécifiques lors de l'évaluation des objets Amazon S3 dans le chemin d'inclusion (`include path`) spécifié.

Lorsque vous configurez le robot d'exploration à l'aide du AWS CLI, définissez l'option de configuration suivante :

```
aws glue update-crawler \  
  --name myCrawler \  
  --configuration '{"Version": 1.0, "Grouping": {"TableGroupingPolicy":  
    "CombineCompatibleSchemas" } }'
```

API

Lorsque vous configurez l'crawler à l'aide de l'API, définissez les options de configuration suivantes :


Définissez le champ `Configuration` avec une représentation de chaîne de l'objet JSON suivant dans l'API de l'crawler ; par exemple :

```
{
  "Version": 1.0,
  "Grouping": {
    "TableGroupingPolicy": "CombineCompatibleSchemas" }
}
```

Spécification de l'emplacement de la table et du niveau de partitionnement

Par défaut, lorsqu'un robot définit des tables pour les données stockées dans Amazon S3, il tente de fusionner les schémas et de créer des tables de niveau supérieur (). `year=2019` Dans certains cas, vous pouvez vous attendre à ce que l'crawler crée une table pour le dossier `month=Jan`, mais à la place, l'crawler crée une partition puisqu'un dossier frère (`month=Mar`) a été fusionné dans la même table.

L'option d'crawler au niveau de la table vous offre la possibilité d'indiquer à l'crawler où se trouvent les tables et comment vous souhaitez que les partitions soient créées. Lorsque vous spécifiez un `Table level` (Niveau de la table), la table est créée à ce niveau absolu à partir du compartiment Amazon S3.



Lorsque vous configurez l'crawler sur la console, vous pouvez spécifier une valeur pour l'option d'crawler Table level (Niveau de la table). La valeur doit être un entier positif qui indique l'emplacement de la table (niveau absolu dans le jeu de données). Le niveau du dossier de niveau supérieur est 1. Par exemple, pour le chemin `mydataset/year/month/day/hour`, si le niveau est défini sur 3, la table est créée à l'emplacement `mydataset/year/month`.

AWS Management Console

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez Crawlers dans le catalogue de données.

3. Lorsque vous configurez un robot d'exploration, sous Sortie et planification, choisissez Niveau de table sous Options avancées.

Step 1
Set crawler properties

Step 2
Choose data sources and classifiers

Step 3
Configure security settings

Step 4
Set output and scheduling

Step 5
Review and create

Set output and scheduling

Output configuration

Target database
0-test-catalog

Clear selection Add database

Table name prefix - *optional*
Type a prefix added to table names

Maximum table threshold - *optional*
This field sets the maximum number of tables the crawler is allowed to generate. In the event that this number is surpassed, the crawl will fail with an error. If not set, the crawler will automatically generate the number of tables depending on the data schema.
Type a number greater than 0

Advanced options

S3 schema grouping

☐ Create a single schema for each S3 path
By default, when a crawler defines tables for data stored in S3, it considers both data compatibility and schema similarity. Select this check box to group compatible schemas into a single table definition across all S3 objects under the provided include path. Other criteria will still be considered to determine proper grouping.

Table level - *optional*
The value must be a positive integer that indicates table location (the absolute level in the dataset). The level for the top level folder is 1. For example, for the path mydataset/a/b, if the level is set to 3, the table is created at location mydataset/a/b.

5

AWS CLI

Lorsque vous configurez le robot à l'aide du AWS CLI, définissez le configuration paramètre comme indiqué dans l'exemple de code :

```
aws glue update-crawler \
  --name myCrawler \
  --configuration '{"Version": 1.0, "Grouping": { "TableLevelConfiguration": 2 } }'
```

API

Lorsque vous configurez l'crawler à l'aide de l'API, définissez le champ Configuration avec une représentation de chaînes de l'objet JSON suivant ; par exemple :

```
configuration = jsonencode(
{
  "Version": 1.0,
  "Grouping": {
```

```
        TableLevelConfiguration = 2
    }
})
```

CloudFormation

Dans cet exemple, vous définissez l'option de niveau de table disponible dans la console au sein de votre CloudFormation modèle :

```
"Configuration": "{
  \"Version\":1.0,
  \"Grouping\":{\"TableLevelConfiguration\":2}
}"
```

Spécifier le nombre maximum de tables que le robot d'exploration est autorisé à créer

Vous pouvez éventuellement spécifier le nombre maximum de tables que le robot d'exploration est autorisé à créer en spécifiant un `TableThreshold` via la AWS Glue console ou AWS CLI. Si les tables détectées par le crawler lors de son analyse sont supérieures à cette valeur d'entrée, l'analyse échoue et aucune donnée n'est écrite dans le catalogue de données.

Ce paramètre est utile lorsque les tables qui seraient détectées et créées par le crawler sont beaucoup plus grandes que vos prévisions. Cela peut être dû à plusieurs raisons, notamment :

- Lorsque vous utilisez une AWS Glue tâche pour renseigner vos emplacements Amazon S3, vous pouvez vous retrouver avec des fichiers vides au même niveau qu'un dossier. Dans de tels cas, lorsque vous exécutez un crawler sur cet emplacement Amazon S3, le crawler crée plusieurs tables en raison de la présence de fichiers et de dossiers au même niveau.
- Si vous ne configurez pas `"TableGroupingPolicy": "CombineCompatibleSchemas"`, vous pourriez vous retrouver avec plus de tables que prévu.

Vous devez spécifier la propriété `TableThreshold` sous forme d'une valeur de nombre entier supérieure à 0. Cette valeur est configurée par crawler. Cela signifie qu'elle est prise en compte pour chaque analyse. Par exemple : un crawler a la valeur `TableThreshold` définie sur 5. Lors de chaque analyse, AWS Glue compare le nombre de tables détectées à cette valeur seuil de table (5) et, si le nombre de tables détectées est inférieur à 5, AWS Glue écrit les tables dans le catalogue de données. Sinon, l'analyse échoue sans écriture dans le catalogue de données.

AWS Management Console

Pour effectuer le réglage **TableThreshold** à l'aide de AWS Management Console :

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Lors de la configuration d'un robot, dans Sortie et planification, définissez le seuil de table maximal sur le nombre de tables que le robot est autorisé à générer.

Set output and scheduling

Output configuration Info

Target database
Choose a database

Clear selection Add database

Table name prefix - optional
Type a prefix added to table names

Maximum table threshold - optional
This field sets the maximum number of tables the crawler is allowed to generate. In the event that this number is surpassed, the crawl will fail with an error. If not set, the crawler will automatically generate the number of tables depending on the data schema.
Type a number greater than 0

► Advanced options

AWS CLI

Pour effectuer le réglage TableThreshold à l'aide de AWS CLI :

```
aws glue update-crawler \
  --name myCrawler \
  --configuration '{"Version": 1.0, "CrawlerOutput": {"Tables":
    { "TableThreshold": 5 }}}'
```

API

Pour configurer à TableThreshold l'aide de l'API :

```
{"Version":1.0,
"CrawlerOutput":
{"Tables":{"AddOrUpdateBehavior":"MergeNewColumns",
"TableThreshold":5}}};
```

Les messages d'erreur sont consignés pour vous aider à identifier les chemins d'accès aux tables et à nettoyer vos données. Exemple de journal dans votre compte si le crawler échoue, parce que le nombre de tables était supérieur à la valeur du seuil de tables fournie :

Table Threshold value = 28, Tables detected - 29

Dans CloudWatch, nous enregistrons tous les emplacements de table détectés sous forme de message INFO. Une erreur est consignée comme motif de l'échec.

```
ERROR com.amazonaws.services.glue.customerLogs.CustomerLogService - CustomerLogService
received CustomerFacingException with message
The number of tables detected by crawler: 29 is greater than the table threshold value
provided: 28. Failing crawler without writing to Data Catalog.
com.amazonaws.services.glue.exceptions.CustomerFacingInternalException: The number of
tables detected by crawler: 29 is greater than the table threshold value provided:
28.
Failing crawler without writing to Data Catalog.
```

Configuration d'un robot d'exploration pour utiliser les informations d'identification de Lake Formation

Vous pouvez configurer un robot d'exploration pour qu'il utilise des AWS Lake Formation informations d'identification pour accéder à un magasin de données Amazon S3 ou à une table de catalogue de données contenant un emplacement Amazon S3 sous-jacent au même Compte AWS ou à un autre Compte AWS. Vous pouvez configurer une table du catalogue de données existante en tant que cible d'un crawler, si le crawler et la table du catalogue de données se trouvent dans le même compte. Actuellement, une seule cible de catalogue avec une seule table de catalogue est autorisée lors de l'utilisation d'une table de catalogue de données comme cible d'un robot d'exploration.

Note

Lorsque vous définissez une table du catalogue de données en tant que cible du crawler, assurez-vous que l'emplacement sous-jacent de la table du catalogue de données est un emplacement Amazon S3. Les crawlers qui utilisent les informations d'identification Lake Formation ne prennent en charge que les cibles du catalogue de données avec des emplacements Amazon S3 sous-jacents

Configuration requise lorsque le crawler et l'emplacement Amazon S3 enregistré ou la table du catalogue de données se trouvent dans le même compte (indexation de site web intégrée au compte)

Pour permettre au crawler d'accéder à un magasin de données ou à une table du catalogue de données à l'aide des informations d'identification de Lake Formation, vous devez enregistrer

l'emplacement des données auprès de Lake Formation. En outre, le rôle IAM du crawler doit être autorisé à lire les données depuis la destination où le compartiment Amazon S3 est enregistré.

Vous pouvez effectuer les étapes de configuration suivantes à l'aide du AWS Management Console ou AWS Command Line Interface (AWS CLI).

AWS Management Console

1. Avant de configurer un crawler pour accéder à sa source, enregistrez l'emplacement des données du magasin de données ou du catalogue de données auprès de Lake Formation. Dans la console Lake Formation (<https://console.aws.amazon.com/lakeformation/>), enregistrez un emplacement Amazon S3 comme emplacement racine de votre lac de données dans l'Compte AWS endroit où le robot est défini. Pour plus d'informations, consultez la rubrique [Enregistrement d'un emplacement Amazon S3](#).
2. Accordez des autorisations Emplacement des données au rôle IAM utilisé pour l'exécution du crawler afin que celui-ci puisse lire les données depuis la destination dans Lake Formation. Pour plus d'informations, consultez la rubrique [Octroi d'autorisations d'emplacement de données \(même compte\)](#).
3. Accordez les autorisations d'accès au rôle de crawler (Create) à la base de données, qui est spécifiée comme base de données de sortie. Pour plus d'informations, consultez la rubrique [Octroi d'autorisations de base de données via la console Lake Formation et la méthode de ressource nommée](#).
4. Dans la console IAM (<https://console.aws.amazon.com/iam/>), créez un rôle IAM pour le robot d'exploration. Ajoutez la stratégie `lakeformation:GetDataAccess` au rôle.
5. Dans la AWS Glue console (<https://console.aws.amazon.com/glue/>), lors de la configuration du robot d'exploration, sélectionnez l'option Utiliser les informations d'identification de Lake Formation pour analyser la source de données Amazon S3.

Note

Le champ `accountId` est facultatif pour l'indexation de site web intégrée au compte.

AWS CLI

```
aws glue --profile demo create-crawler --debug --cli-input-json '{
  "Name": "prod-test-crawler",
```

```

    "Role": "arn:aws:iam::111122223333:role/service-role/AWSGlueServiceRole-prod-
test-run-role",
    "DatabaseName": "prod-run-db",
    "Description": "",
    "Targets": {
    "S3Targets":[
        {
            "Path": "s3://amzn-s3-demo-bucket"
        }
    ]
    },
    "SchemaChangePolicy": {
        "UpdateBehavior": "LOG",
        "DeleteBehavior": "LOG"
    },
    "RecrawlPolicy": {
        "RecrawlBehavior": "CRAWL_EVERYTHING"
    },
    "LineageConfiguration": {
        "CrawlerLineageSettings": "DISABLE"
    },
    "LakeFormationConfiguration": {
        "UseLakeFormationCredentials": true,
        "AccountId": "111122223333"
    },
    "Configuration": {
        "Version": 1.0,
        "CrawlerOutput": {
            "Partitions": { "AddOrUpdateBehavior": "InheritFromTable" },
            "Tables": { "AddOrUpdateBehavior": "MergeNewColumns" }
        },
        "Grouping": { "TableGroupingPolicy": "CombineCompatibleSchemas" }
    },
    "CrawlerSecurityConfiguration": "",
    "Tags": {
        "KeyName": ""
    }
}

```

Configuration requise lorsque le crawler et l'emplacement Amazon S3 enregistré se trouvent dans des comptes différents (indexation de site web entre comptes)

Pour permettre au crawler d'accéder à un magasin de données sur un autre compte à l'aide des informations d'identification Lake Formation, vous devez d'abord enregistrer l'emplacement des données Amazon S3 auprès de Lake Formation. Ensuite, vous accordez des autorisations de localisation des données au compte du crawler en procédant comme suit.

Vous pouvez effectuer les étapes suivantes à l'aide du AWS Management Console ou AWS CLI.

AWS Management Console

1. Dans le compte sur lequel l'emplacement Amazon S3 est enregistré (compte B) :
 - a. Enregistrez un chemin Amazon S3 dans Lake Formation. Pour plus d'informations, consultez la rubrique [Enregistrement d'un emplacement Amazon S3](#).
 - b. Accordez des autorisations Data location (Emplacement des données) au compte (compte A) sur lequel le crawler sera exécuté. Pour plus d'informations, consultez la rubrique [Octroi d'autorisations d'emplacement de données](#).
 - c. Créez une base de données vide dans Lake Formation avec l'emplacement sous-jacent comme emplacement Amazon S3 cible. Pour plus d'informations, consultez la rubrique [Création d'une base de données](#).
 - d. Accordez au compte A (le compte sur lequel le crawler sera exécuté) l'accès à la base de données que vous avez créée à l'étape précédente. Pour plus d'informations, consultez la rubrique [Octroi d'autorisations de base de données](#).
2. Dans le compte sur lequel le crawler est créé et sera exécuté (compte A) :
 - a. À l'aide de la AWS RAM console, acceptez la base de données partagée depuis le compte externe (compte B). Pour plus d'informations, consultez la section [Acceptation d'une invitation de partage de ressources provenant de AWS Resource Access Manager](#).
 - b. Créez un rôle IAM pour le crawler. Ajoutez une stratégie `lakeformation:GetDataAccess` au rôle.
 - c. Dans la console Lake Formation (<https://console.aws.amazon.com/lakeformation/>), accordez des autorisations de localisation des données sur l'emplacement Amazon S3 cible au rôle IAM utilisé pour l'exécution du robot d'exploration afin que celui-ci puisse lire les données depuis la destination dans Lake Formation. Pour plus d'informations, consultez la rubrique [Octroi d'autorisations d'emplacement de données](#).

- d. Créez un lien de ressource sur la base de données partagée. Pour plus d'informations, consultez la rubrique [Création d'un lien de ressources](#).
- e. Accordez les autorisations d'accès au rôle de crawler (Create) sur la base de données partagée et (Describe) le lien de ressource. Le lien de ressource est spécifié dans la sortie du crawler.
- f. Dans la AWS Glue console (<https://console.aws.amazon.com/glue/>), lors de la configuration du robot d'exploration, sélectionnez l'option Utiliser les informations d'identification de Lake Formation pour analyser la source de données Amazon S3.

Pour l'exploration entre comptes, spécifiez l' Compte AWS ID auquel l'emplacement Amazon S3 cible est enregistré auprès de Lake Formation. Le champ accountId est facultatif pour l'indexation de site web intégrée au compte.

Step 1
Set crawler properties

Step 2
Choose data sources and classifiers

Step 3
Configure security settings

Step 4
Set output and scheduling

Step 5
Review and create

Configure security settings

IAM role

Existing IAM role
Choose an option

Create new IAM role Update chosen IAM role

Only IAM roles created by the AWS Glue console and have the prefix "AWSGlueServiceRole-" can be updated.

Lake Formation configuration - optional
Allow the crawler to use Lake Formation credentials for crawling the data source.

☒ Use Lake Formation credentials for crawling S3 data source
Checking this box will allow the crawler to use Lake Formation credentials for crawling the data source. If the data source belongs to another account, you must provide the registered account ID. Otherwise, the crawler will crawl only those data sources associated to the account. Only applicable to S3 and Glue Catalog data sources.

Location of S3 data
☐ In this account
☒ In a different account

Account ID
111111111111
Must be a valid account ID, containing only numbers (0-9) and 12 characters long.

► **Security configuration - optional**
Enable at-rest encryption with a security configuration.

Cancel Previous Next

AWS CLI

```
aws glue --profile demo create-crawler --debug --cli-input-json '{
  "Name": "prod-test-crawler",
  "Role": "arn:aws:iam::111122223333:role/service-role/AWSGlueServiceRole-prod-test-run-role",
  "DatabaseName": "prod-run-db",
```

```

    "Description": "",
    "Targets": {
      "S3Targets": [
        {
          "Path": "s3://amzn-s3-demo-bucket"
        }
      ],
    },
    "SchemaChangePolicy": {
      "UpdateBehavior": "LOG",
      "DeleteBehavior": "LOG"
    },
    "RecrawlPolicy": {
      "RecrawlBehavior": "CRAWL_EVERYTHING"
    },
    "LineageConfiguration": {
      "CrawlerLineageSettings": "DISABLE"
    },
    "LakeFormationConfiguration": {
      "UseLakeFormationCredentials": true,
      "AccountId": "111111111111"
    },
    "Configuration": {
      "Version": 1.0,
      "CrawlerOutput": {
        "Partitions": { "AddOrUpdateBehavior": "InheritFromTable" },
        "Tables": { "AddOrUpdateBehavior": "MergeNewColumns" }
      },
      "Grouping": { "TableGroupingPolicy": "CombineCompatibleSchemas" }
    },
    "CrawlerSecurityConfiguration": "",
    "Tags": {
      "KeyName": ""
    }
  }
}'

```

Note

- Un crawler utilisant les informations d'identification Lake Formation n'est pris en charge que pour les cibles Amazon S3 et du catalogue de données.

- Pour les cibles utilisant le distributeur d'informations d'identification Lake Formation, les emplacements Amazon S3 sous-jacents doivent appartenir au même compartiment. Par exemple, la possibilité pour les clients d'utiliser plusieurs cibles (s3://amzn-s3-demo-bucket1/folder1, s3://amzn-s3-demo-bucket1/folder2) as long as all target locations are under the same bucket (amzn-s3-demo-bucket1). Specifying different buckets (s3://amzn-s3-demo-bucket1/folder1, s3://amzn-s3-demo-bucket2/folder 2) n'est pas autorisée.
- Actuellement, pour les crawlers de cible du catalogue de données, une seule cible de catalogue avec une seule table de catalogue est autorisée.

Accélération des analyseurs à l'aide des notifications d'événements Amazon S3

Au lieu de répertorier les objets d'une cible Amazon S3 ou de Catalogue de données, vous pouvez configurer le Crawler pour qu'il utilise les événements Amazon S3 pour trouver les modifications éventuelles. Cette fonction améliore le temps de nouvelle analyse en utilisant les événements Amazon S3 pour identifier les changements entre deux analyses. Ce processus s'effectue en répertoriant tous les fichiers du sous-dossier qui a déclenché l'événement au lieu de répertorier la cible Amazon S3 ou du Catalogue de données complète.

La première analyse répertorie tous les objets Amazon S3 de la cible. Après la première analyse réussie, vous pouvez choisir de faire une nouvelle analyse manuellement ou selon un calendrier défini. L'crawler indiquera uniquement les objets de ces événements au lieu de répertorier tous les objets.

Lorsque la cible est une table du catalogue de données, le robot met à jour les tables existantes du catalogue de données avec les modifications (par exemple, des partitions supplémentaires dans une table).

Passer à un crawler basé sur les événements Amazon S3 a les avantages suivants :

- Une nouvelle analyse plus rapide, car la liste de tous les objets de la cible n'est pas nécessaire ; toutefois, la liste de dossiers spécifiques est effectuée là où des objets sont ajoutés ou supprimés.
- Une réduction du coût global d'analyse étant donné que la liste de dossiers spécifiques est effectuée lorsque des objets sont ajoutés ou supprimés.

L'analyse des événements Amazon S3 s'exécute en consommant des événements Amazon S3 depuis la file d'attente SQS en fonction de la planification de l'crawler. Il n'y aura aucun coût s'il n'y a pas d'événements dans la file d'attente. Les événements Amazon S3 peuvent être configurés

pour accéder directement à la file d'attente SQS ou, dans les cas où plusieurs consommateurs ont besoin du même événement, une combinaison de SNS et de SQS. Pour de plus amples informations, veuillez consulter [the section called “Configuration de votre compte pour les notifications d'événements Amazon S3”](#).

Après avoir créé et configuré le Crawler en mode événement, la première analyse s'exécute en mode de liste en répertoriant la liste de la cible Amazon S3 ou du Catalogue de données complète. Le journal suivant confirme l'opération de l'analyse en consommant des événements Amazon S3 après la première analyse réussie : « L'analyse est exécutée en consommant des événements Amazon S3. »

Après avoir créé l'analyse des événements Amazon S3 et mis à jour les propriétés de l'crawler susceptibles d'avoir un impact sur l'analyse, l'analyse fonctionne en mode liste et le journal suivant est ajouté : « L'analyse n'est pas exécutée en mode événement S3 ».

 Note

Le nombre maximum de messages à consommer est de 100 000 messages par crawl.

Considérations et restrictions

Les considérations et limitations suivantes s'appliquent lorsque vous configurez un robot d'exploration pour qu'il utilise les notifications d'événements Amazon S3 afin de détecter des modifications.

- Comportement important avec les partitions supprimées

Lorsque vous utilisez les robots d'exploration d'événements Amazon S3 avec les tables du catalogue de données :

- Si vous supprimez une partition à l'aide de l'appel d'API `DeletePartitionAPI`, vous devez également supprimer tous les objets S3 situés sous cette partition et sélectionner Tous les événements de suppression d'objets lorsque vous configurez vos notifications d'événements S3. Si les événements de suppression ne sont pas configurés, le robot d'exploration recrée la partition supprimée lors de sa prochaine exécution.
- Seule une cible unique est prise en charge par le Crawler, que ce soit pour les cibles Amazon S3 ou du Catalogue de données.
- Un SQS sur un VPC privé n'est pas pris en charge.
- L'échantillonnage Amazon S3 n'est pas pris en charge.

- La cible du crawler doit être un dossier pour une cible Amazon S3, ou une ou plusieurs AWS Glue Tables de catalogue de données pour une cible de catalogue de données.
- Le caractère générique du chemin « tout » n'est pas pris en charge : s3://%
- Pour une cible de Catalogue de données, toutes les tables du catalogue doivent pointer vers le même compartiment Amazon S3 pour le mode événement Amazon S3.
- Pour une cible de Catalogue de données, une table de catalogue ne doit pas pointer vers un emplacement Amazon S3 au format Delta Lake (contenant des dossiers _symlink ou vérifiant le InputFormat de la table du catalogue).

Rubriques

- [Configuration de votre compte pour les notifications d'événements Amazon S3](#)
- [Configuration d'un robot d'exploration pour les notifications d'événements Amazon S3 pour une cible Amazon S3](#)
- [Configuration d'un robot d'exploration pour les notifications d'événements Amazon S3 pour une table de catalogue de données](#)

Configuration de votre compte pour les notifications d'événements Amazon S3

Réalisez les tâches de configuration suivantes. Notez que les valeurs entre parenthèses font référence aux paramètres configurables du script.

1. Vous devez configurer les notifications d'événements pour votre compartiment Amazon S3.

Pour plus d'informations, consultez les [notifications d'événements Amazon S3](#).

2. Pour utiliser le robot basé sur les événements Amazon S3, vous devez activer la notification des événements sur le compartiment Amazon S3 avec des événements filtrés à partir du préfixe identique à la cible S3 et les stocker dans SQS. Vous pouvez configurer SQS et les notifications d'événements via la console en suivant les étapes décrites dans [Procédure pas à pas : Configuration d'un compartiment pour les notifications](#).
3. Ajoutez la politique SQS suivante au rôle utilisé par le robot d'exploration.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "VisualEditor0",
```



```

    "Effect": "Allow",
    "Action": [
        "sqs:DeleteMessage",
        "sqs:GetQueueUrl",
        "sqs:ListDeadLetterSourceQueues",
        "sqs:ReceiveMessage",
        "sqs:GetQueueAttributes",
        "sqs:ListQueueTags",
        "sqs:SetQueueAttributes",
        "sqs:PurgeQueue"
    ],
    "Resource": "arn:aws:sqs:{region}:{accountID}:cfn-sqs-queue"
}
]
}

```

Configuration d'un robot d'exploration pour les notifications d'événements Amazon S3 pour une cible Amazon S3

Suivez ces étapes pour configurer un robot d'exploration pour les notifications d'événements Amazon S3 pour une cible Amazon S3 à l'aide du AWS Management Console ou AWS CLI.

AWS Management Console

1. Connectez-vous à la GuardDuty console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/guardduty/>.
2. Définissez les propriétés de votre crawler. Pour plus d'informations, consultez la section [Configuration des options de configuration du robot d'exploration sur AWS Glue console](#).
3. Dans la section Configuration de la source de données, il vous est demandé si vos données sont déjà mappées à AWS Glue des tables ?

Par défaut, la réponse Not yet (Pas encore) est déjà sélectionnée. Laissez-le comme valeur par défaut car vous utilisez une source de données Amazon S3 et les données ne sont pas déjà mappées vers AWS Glue tables.

4. Dans la section Data sources (Sources de données), choisissez Add a data source (Ajouter une source de données).

Step 1
Set crawler properties

Step 2
Choose data sources and classifiers

Step 3
Configure security settings

Step 4
Set output and scheduling

Step 5
Review and create

Choose data sources and classifiers

Data source configuration

Is your data already mapped to Glue tables?

☒ Not yet
Select one or more data sources to be crawled.

☐ Yes
Select existing tables from your Glue Data Catalog.

Data sources (0)
The list of data sources to be scanned by the crawler.

Edit Remove Add a data source

Type	Data source	Parameters
You don't have any data sources.		

Add a data source

► **Custom classifiers - optional**
A classifier checks whether a given file is in a format the crawler can handle. If it is, the classifier creates a schema in the form of a StructType object that matches that data format.

Cancel Previous Next

5. Dans le modal Add data source (Ajouter une source de données), configurez la source de données Amazon S3 :
 - Data source (Source de données) : Amazon S3 est sélectionné par défaut.
 - Network connection (Connexion réseau) (Facultatif) : sélectionnez Add new connection (Ajouter une nouvelle connexion).
 - Location of Amazon S3 data (Emplacement des données Amazon S3) : par défaut, l'option In this account (Dans ce compte) est sélectionnée.
 - Amazon S3 path (Chemin d'accès Amazon S3) : spécifiez le chemin d'accès Amazon S3 où les dossiers et les fichiers sont analysés.
 - Subsequent crawler runs (Exécutions ultérieures du crawler) : choisissez Crawl based on events (Analyse en fonction des événements) pour utiliser les notifications d'événements Amazon S3 pour votre crawler.
 - Include SQS ARN (Inclure un ARN SQS) : spécifiez les paramètres du magasin de données, y compris l'ARN SQS valide. (Par exemple, `arn:aws:sqs:region:account:sqs.`)
 - Include dead-letter SQS ARN (Inclure un ARN SQS de lettres mortes) (Facultatif) : spécifiez un ARN SQS de lettres mortes Amazon valide. (Par exemple, `arn:aws:sqs:region:account:deadLetterQueue.`)
 - Choisissez Add an Amazon S3 data source (Ajouter une source de données Amazon S3).

Introducing the new AWS Glue Crawlers console experience
We've redesigned the AWS Glue Crawlers page to make it easier to use. Let us know what you think. Or you can use the old console.

Add data source

Step 1
Set crawler properties

Step 2
Choose data sources and classifiers

Step 3
Configure security settings

Step 4
Set output and scheduling

Step 5
Review and create

Data source
Choose the source of data to be crawled.
S3

Network connection - optional
Optionally include a Network connection to use with this S3 target. Note that each crawler is limited to one Network connection so any other S3 targets will also use the same connection (or none, if left blank).

Location of S3 data
☒ In this account
☐ In a different account

S3 path
Browse for or enter an existing S3 path.
s3://test View Browse

Subsequent crawler runs
This field is a global field that affects all S3 data sources.
☐ Crawl all sub-folders
Crawl all folders again with every subsequent crawl.
☐ Crawl new sub-folders only
Only Amazon S3 folders that were added since the last crawl will be crawled. If the schemas are compatible, new partitions will be added to existing tables.
☒ Crawl based on events
Rely on Amazon S3 events to control what folders to crawl.

Include SQS ARN
Specify the SQS ARN to use for identifying changes to crawl.
arn:aws:sqs:region:account:sqs
SQS ARN must follow the following syntax: arn:aws:sqs:region:account:sqs

Include dead-letter SQS ARN - optional
Optionally specify a corresponding Dead-letter SQS ARN for unprocessed messages.
arn:aws:sqs:region:account:deadLetterQueue
Dead-letter SQS ARN must follow the following syntax:
arn:aws:sqs:region:account:deadLetterQueue

☐ Sample only a subset of files
☐ Exclude files matching pattern

Cancel Add an S3 data source

AWS CLI

Voici un exemple d' AWS CLI appel Amazon S3 pour configurer un robot d'exploration afin qu'il utilise les notifications d'événements pour explorer un compartiment cible Amazon S3.

Create Crawler:

```
aws glue update-crawler \
  --name myCrawler \
  --recrawl-policy RecrawlBehavior=CRAWL_EVENT_MODE \
  --schema-change-policy UpdateBehavior=UPDATE_IN_DATABASE,DeleteBehavior=LOG
  --targets '{"S3Targets":[{"Path":"s3://amzn-s3-demo-bucket/", "EventQueueArn":
    "arn:aws:sqs:us-east-1:012345678910:MyQueue"}]}'
```

Configuration d'un robot d'exploration pour les notifications d'événements Amazon S3 pour une table de catalogue de données

Lorsque vous disposez d'une table de catalogue de données, configurez un robot d'exploration pour les notifications d'événements Amazon S3 à l'aide du AWS Glue console :

1. Définissez les propriétés de votre crawler. Pour plus d'informations, consultez la section [Configuration des options de configuration du robot d'exploration sur le AWS Glue console](#).
2. Dans la section Configuration de la source de données, il vous est demandé si vos données sont déjà mappées à AWS Glue des tables ?

Sélectionnez Yes (Oui) pour choisir les tables existantes de votre Catalogue de données comme source de données.

3. Dans la section Glue tables (Tables Glue), choisissez Add tables (Ajouter des tables).

The screenshot shows the AWS Glue console interface for configuring a crawler. On the left, a sidebar lists five steps: Step 1 (Set crawler properties), Step 2 (Choose data sources and classifiers), Step 3 (Configure security settings), Step 4 (Set output and scheduling), and Step 5 (Review and create). Step 2 is currently selected. The main panel is titled 'Choose data sources and classifiers' and contains a 'Data source configuration' section. This section asks 'Is your data already mapped to Glue tables?' with two radio button options: 'Not yet' (which prompts to 'Select one or more data sources to be crawled.') and 'Yes' (which is selected and prompts to 'Select existing tables from your Glue Data Catalog.'). Below this is a 'Glue tables (0)' section with an 'Info' icon and buttons for 'Edit', 'Remove', and 'Add tables'. A descriptive text states 'The list of AWS Glue Catalog tables to be scanned by the crawler.' Below this is a table with two columns: 'Database' and 'Tables'. The table is currently empty, with a message 'You don't have any catalog table sources.' and an 'Add tables' button at the bottom.

4. Dans le modal Add table (Ajouter une table), configurez la base de données et les tables :
 - Network connection (Connexion réseau) (Facultatif) : sélectionnez Add new connection (Ajouter une nouvelle connexion).
 - Database (Base de données) : sélectionnez une base de données dans le Catalogue de données.

- Tables : sélectionnez une ou plusieurs tables de cette base de données dans le Catalogue de données.
- Subsequent crawler runs (Exécutions ultérieures du crawler) : choisissez Crawl based on events (Analyse en fonction des événements) pour utiliser les notifications d'événements Amazon S3 pour votre crawler.
- Include SQS ARN (Inclure un ARN SQS) : spécifiez les paramètres du magasin de données, y compris l'ARN SQS valide. (Par exemple, `arn:aws:sqs:region:account:sqs.`)
- Include dead-letter SQS ARN (Inclure un ARN SQS de lettres mortes) (Facultatif) : spécifiez un ARN SQS de lettres mortes Amazon valide. (Par exemple, `arn:aws:sqs:region:account:deadLetterQueue.`)
- Choisissez Confirmer.

Add Glue tables ✕

Network connection - optional
Optionally include a Network connection to use with this Catalog target. Note that only one Catalog target is allowed for Catalog Crawlers with a VPC connection.

↻

Clear selection Add new connection [↗](#)

Database
Select a Glue Catalog database

↻

Tables
Select one or more Glue Catalog Tables

↻

countries_json ✕ organizations_json ✕

Clear selection

Subsequent crawler runs
This field is a global field that affects all glue table sources.

☐ Crawl all sub-folders
Crawl all folders again with every subsequent crawl.

☒ Crawl based on events
Rely on Amazon S3 events to control what folders to crawl.

Include SQS ARN
Specify the SQS ARN to use for identifying changes to crawl.

SQS ARN must follow the following syntax: arn:aws:sqs:region:account:sqs

Include dead-letter SQS ARN - optional
Optionally specify a corresponding Dead-letter SQS ARN for unprocessed messages.

Dead-letter SQS ARN must follow the following syntax:
arn:aws:sqs:region:account:deadLetterQueue

Cancel Confirm

Tutoriel : Ajouter un AWS Glue chenille

Pour cela AWS Glue Dans ce scénario, il vous est demandé d'analyser les données d'arrivée des principaux transporteurs aériens afin de calculer la popularité des aéroports de départ mois après mois. Vous disposez de données de vols pour l'année 2016 au format CSV stockées dans Amazon S3. Avant de transformer et d'analyser vos données, vous devez cataloguer leurs métadonnées dans le AWS Glue Data Catalog.

Dans ce didacticiel, ajoutons un crawler qui déduit les métadonnées de ces journaux de vol dans Amazon S3 et crée une table dans votre catalogue de données.

Rubriques

- [Prérequis](#)
- [Étape 1 : Ajouter un crawler](#)
- [Étape 2 : Exécuter le crawler](#)
- [Étape 3 : Afficher AWS Glue Data Catalog objects](#)

Prérequis


Ce didacticiel suppose que vous possédez un AWS compte et que vous avez accès à AWS Glue.

Étape 1 : Ajouter un crawler

Procédez comme suit pour configurer et exécuter un crawler qui extrait les métadonnées d'un fichier CSV stocké dans Amazon S3.

Pour créer un crawler qui lit les fichiers stockés sur Amazon S3

1. Sur la console AWS Glue de service, dans le menu de gauche, choisissez Crawlers.
2. Sur la page Crawlers, sélectionnez Créer un Crawler. Cela démarre une série de pages qui vous invitent à saisir les détails du crawler.



The screenshot shows the AWS Glue Crawlers console. At the top, there's a breadcrumb 'AWS Glue > Crawlers'. Below it, the title 'Crawlers' is followed by a description: 'A crawler connects to a data store, progresses through a prioritized list of classifiers to determine the schema for your data, and then creates metadata tables in your data catalog.' Below this, there's a section for 'Crawlers (1) Info' with a subtext 'View and manage all available crawlers.' To the right, it says 'Last updated (UTC) October 8, 2023 at 03:31:34' with a refresh icon. There are buttons for 'Action', 'Run', and 'Create crawler'. Below this is a search bar labeled 'Filter crawlers'. At the bottom, there's a table with columns: Name, State, Schedule, Last run, Last run..., Log, and Table changes from last run. The table contains one entry: 'sample cra...' with state 'Ready', last run 'Succeeded' on 'January 7, ...', and '1 created' table changes.

	Name	State	Schedule	Last run	Last run...	Log	Table changes from last run
☐	sample cra...	Ready		Succeeded	January 7, ...	View log	1 created

3. Dans le champ Nom de l'analyseur, saisissez **Flights Data Crawler**, et sélectionnez Suivant.

Les crawlers invoquent les classifieurs pour déduire le schéma de vos données. Ce didacticiel utilise le classifieur intégré pour CSV par défaut.

4. Pour le type de source du crawler, sélectionnez Data stores (Magasins de données), puis Next (Suivant).
5. Maintenant, faisons pointer le crawler vers vos données. Sur la page Add a data store (Ajouter un magasin de données), sélectionnez le magasin de données Amazon S3. Ce tutoriel n'utilise pas de connexion, alors laissez le champ Connection (Connexion) vide s'il est visible.

Pour l'option Crawl data in (Analyser les données dans), sélectionnez Specified path in another account (Chemin d'accès spécifié dans un autre compte). Ensuite, pour Inclure le chemin, saisissez le chemin où le crawler peut trouver les données de vol, qui est **s3://crawler-public-us-east-1/flight/2016/csv**. Après avoir saisi le chemin d'accès, le titre de ce champ devient Include path (Inclure le chemin). Choisissez Suivant.

6. Vous pouvez analyser plusieurs magasins de données avec un seul crawler. Cependant, dans ce tutoriel, nous n'utilisons qu'un seul magasin de données, alors sélectionnez No (Non), puis Next (Suivant).
7. Le robot d'exploration a besoin d'autorisations pour accéder au magasin de données et créer des objets dans le AWS Glue Data Catalog. Pour configurer ces autorisations, choisissez Create an IAM role. Le nom du rôle IAM commence par **AWSGlueServiceRole-**, et dans le champ, vous saisissez la dernière partie du nom du rôle. Saisissez **CrawlerTutorial**, puis sélectionnez Save (Enregistrer).

 Note

Pour créer un rôle IAM, votre utilisateur AWS doit avoir les autorisations **CreateRole**, **CreatePolicy** et **AttachRolePolicy**.

L'assistant crée un rôle IAM nommé **AWSGlueServiceRole-CrawlerTutorial**, associe la politique AWS gérée **AWSGlueServiceRole** à ce rôle et ajoute une politique en ligne qui autorise l'accès en lecture à l'emplacement Amazon S3. **s3://crawler-public-us-east-1/flight/2016/csv**

8. Créez une planification pour le crawler. Pour Frequency (Fréquence), sélectionnez Run on demand (Exécuter à la demande), puis Next (Suivant).
9. Les crawlers créent des tables dans votre catalogue de données. Les tables sont contenues dans une base de données dans le catalogue de données. Tout d'abord, sélectionnez Add database (Ajouter une base de données) pour créer une base de données. Dans la

fenêtre contextuelle, saisissez **test-flights-db** pour le nom de la base de données, puis sélectionnez Create (Créer).

Ensuite, saisissez **flights** pour Prefix added to tables (Préfixe ajouté aux tables). Utilisez les valeurs par défaut pour le reste des champs et sélectionnez Next (Suivant).

10. Vérifiez les choix que vous avez fait dans le panneau Add crawler (Ajouter un analyseur) de l'assistant. Si vous voyez des erreurs, vous pouvez choisir Back (Retour) pour revenir aux pages précédentes et apporter des modifications.

Après avoir examiné les informations, sélectionnez Terminer pour créer le crawler.

Étape 2 : Exécuter le crawler

Après avoir créé un crawler, l'assistant vous envoie à la page d'affichage des Crawlers. Étant donné que vous créez le crawler avec une planification à la demande, vous avez la possibilité d'exécuter le crawler.

Pour exécuter un crawler

1. La bannière située en haut de cette page vous indique que le crawler a été créé et vous demande si vous souhaitez l'exécuter maintenant. Sélectionnez Lancez-le maintenant ? pour exécuter le crawler.

La bannière change pour afficher les messages « Tentative d'exécution » et « Exécution » pour votre crawler. Une fois que le crawler démarre, la bannière disparaît et l'affichage du crawler est mis à jour pour afficher l'état Starting (Démarrage) de celui-ci. Après une minute, vous pouvez cliquer sur l'icône Actualiser pour mettre à jour l'état du crawler qui s'affiche dans le tableau.

2. Une fois que le crawler a terminé sa tâche, une nouvelle bannière s'affiche qui décrit les modifications apportées par le crawler. Vous pouvez choisir le test-flights-dblen pour afficher les objets du catalogue de données.

Étape 3 : Afficher AWS Glue Data Catalog objects

Le crawler lit les données à l'emplacement source et crée des tables dans le catalogue de données. Une table est une définition de métadonnées qui représente vos données. Les tables du catalogue de données ne contiennent pas de données. Au lieu de cela, vous utilisez ces tables comme source ou cible dans une définition de tâche.

Pour afficher les objets du catalogue de données créés par le crawler.

1. Dans le panneau de navigation de gauche, sous Data catalog (Catalogue de données), sélectionnez Databases (Bases de données). Ici, vous pouvez voir la base de données `flights-db` qui est créée par le crawler.
2. Dans le panneau de navigation de gauche, sous Data catalog (Catalogue de données), et sous Databases (Bases de données), sélectionnez Tables. Ici, vous pouvez voir la table `flightscsv` qui est créée par le crawler. Si vous sélectionnez le nom de la table, vous pouvez afficher la configuration, les paramètres et les propriétés de la table. En faisant défiler cette vue vers le bas, vous pouvez afficher le schéma, qui est une information sur les colonnes et les types de données de la table.
3. Si vous sélectionnez View partitions (Afficher les partitions) sur la page d'affichage de la table, vous pouvez voir les partitions créées pour les données. La première colonne est la clé de partition.

Définition manuelle des métadonnées

Le catalogue de AWS Glue données est un référentiel central qui stocke les métadonnées relatives à vos sources de données et à vos ensembles de données. Bien qu'un robot d'exploration puisse automatiquement explorer et renseigner les métadonnées des sources de données prises en charge, il existe certains scénarios dans lesquels vous devrez peut-être définir les métadonnées manuellement dans le catalogue de données :

- **Formats de données non pris en charge** : si certaines de vos sources de données ne sont pas prises en charge par le robot d'exploration, vous devez définir manuellement les métadonnées de ces sources de données dans le catalogue de données.
- **Exigences relatives aux métadonnées personnalisées** — Les métadonnées AWS Glue crawler sont déduites en fonction de règles et de conventions prédéfinies. Si vous avez des exigences spécifiques en matière de métadonnées qui ne sont pas couvertes par les métadonnées AWS Glue crawler déduites, vous pouvez définir manuellement les métadonnées pour répondre à vos besoins.
- **Gouvernance et standardisation des données** — Dans certains cas, vous souhaitez peut-être mieux contrôler les définitions des métadonnées pour des raisons de gouvernance, de conformité ou de sécurité des données. La définition manuelle des métadonnées vous permet de vous assurer que celles-ci sont conformes aux normes et politiques de votre organisation.
- **Espace réservé pour une future ingestion de données** : si certaines de vos sources de données ne sont pas immédiatement disponibles ou accessibles, vous pouvez créer des tables de schéma

vides en tant qu'espaces réservés. Une fois les sources de données disponibles, vous pouvez remplir les tables avec les données réelles, tout en conservant la structure prédéfinie.

Pour définir les métadonnées manuellement, vous pouvez utiliser la AWS Glue console, la console Lake Formation, AWS Glue l'API ou le AWS Command Line Interface (AWS CLI). Vous pouvez créer des bases de données, des tables et des partitions, et spécifier des propriétés de métadonnées telles que les noms de colonnes, les types de données, les descriptions et d'autres attributs.

Création de bases de données

Les bases de données sont utilisées pour organiser les tables de métadonnées dans AWS Glue. Lorsque vous définissez une table dans le AWS Glue Data Catalog, vous l'ajoutez à une base de données. Une table ne peut se trouver que dans une seule base de données à la fois.

Votre base de données peut contenir des tables qui définissent les données de différents magasins de données. Ces données peuvent inclure des objets dans Amazon Simple Storage Service (Amazon S3) et des tables relationnelles dans Amazon Relational Database Service.

Note

Lorsque vous supprimez une base de données du AWS Glue Catalogue de données, toutes les tables de la base de données sont également supprimées.

Pour consulter la liste des bases de données, connectez-vous au AWS Management Console et ouvrez le AWS Glue console à <https://console.aws.amazon.com/glue/>. Choisissez Bases de données, puis choisissez un nom de base de données dans la liste pour afficher les détails.

Dans l'onglet Bases de données du AWS Glue console, vous pouvez ajouter, modifier et supprimer des bases de données :

- Pour créer une base de données, choisissez Ajouter une base de données et fournissez un nom et une description. Pour la compatibilité avec d'autres magasins de métadonnées, tels qu'Apache Hive, le nom est en lettres minuscules.

 Note

Si vous prévoyez d'accéder à la base de données depuis Amazon Athena, fournissez un nom contenant uniquement des caractères alphanumériques et des traits de soulignement. Pour plus d'informations, consultez la rubrique [Noms Athena](#).

- Pour modifier la description d'une base de données, cochez la case située en regard du nom de base de données et choisissez Edit (Modifier).
- Pour supprimer une base de données, cochez la case située en regard du nom de base de données et choisissez Remove (Supprimer).
- Pour afficher la liste des tables contenues dans la base de données, choisissez le nom de la base de données et les propriétés de la base de données afficheront alors toutes les tables de la base de données.

Pour modifier la base de données sur laquelle un crawler écrit, vous devez modifier la définition de l'crawler. Pour de plus amples informations, veuillez consulter [Utilisation de robots d'exploration pour alimenter le catalogue de données](#).

Liens de ressources de base de données

Le AWS Glue la console a été récemment mise à jour. La version actuelle de la console ne prend pas en charge les liens de ressources de base de données.

Le catalogue de données peut également contenir des liens de ressources vers des bases de données. Un lien de ressource de base de données est un lien vers une base de données locale ou partagée. Actuellement, vous ne pouvez créer des liens de ressources que dans AWS Lake Formation. Après avoir créé un lien de ressource vers une base de données, vous pouvez utiliser le nom du lien de ressource partout où vous utiliseriez le nom de la base de données. Outre les bases de données que vous possédez ou que vous partagez avec vous, les liens vers les ressources de base de données sont renvoyés par `glue:GetDatabases()` la page Bases de données du AWS Glue console.

Le catalogue de données peut également contenir des liens de ressources de table.

Pour plus d'informations sur les liens de ressources, veuillez consulter la rubrique [Création de liens de ressources](#) dans le Guide du développeur AWS Lake Formation.

Création de tables

Même si l'exécution d'un robot est la méthode recommandée pour inventorier les données de vos magasins de données, vous pouvez y ajouter des tables de métadonnées AWS Glue Data Catalog manuellement. Cette approche vous permet de mieux contrôler les définitions des métadonnées et de les personnaliser en fonction de vos besoins spécifiques.

Vous pouvez également ajouter des tables au catalogue de données manuellement de la manière suivante :

- Utilisez la commande AWS Glue console pour créer manuellement une table dans le AWS Glue Data Catalog. Pour de plus amples informations, veuillez consulter [Création de tables à l'aide de la console](#).
- Utilisez l'opération `CreateTable` de l'[AWS Glue API](#) pour créer une table dans le AWS Glue Data Catalog. Pour de plus amples informations, veuillez consulter [CreateTable action \(Python : créer_table\)](#).
- Utilisez AWS CloudFormation des modèles. Pour de plus amples informations, veuillez consulter [AWS CloudFormation pour AWS Glue](#).

Lorsque vous définissez une table manuellement à l'aide de la console ou d'une API, vous spécifiez le schéma de table et la valeur d'un champ de classification qui indique le type et le format des données de la source de données. Si un crawler crée la table, le format et le schéma des données sont déterminés par un classifieur intégré ou un classifieur personnalisé. Pour plus d'informations sur la création d'une table à l'aide du AWS Glue console, voir [Création de tables à l'aide de la console](#).

Rubriques

- [Partitions de table](#)
- [Liens de ressources de table](#)
- [Création de tables à l'aide de la console](#)
- [Création d'index de partition](#)
- [Mise à jour de tables Data Catalog créées manuellement à l'aide d' crawlers](#)
- [Propriétés de la table Catalogue de données](#)

Partitions de table

Un AWS Glue La définition d'un dossier Amazon Simple Storage Service (Amazon S3) peut décrire une table partitionnée. Par exemple, pour améliorer la performance des requêtes, une table partitionnée peut séparer les données mensuelles dans différents fichiers en utilisant le nom du mois en tant que clé. Entrée AWS Glue, les définitions de table incluent la clé de partitionnement d'une table. Lorsque AWS Glue évalue les données contenues dans les dossiers Amazon S3 pour cataloguer une table, il détermine si une table individuelle ou partitionnée est ajoutée.

Vous pouvez créer des index de partition sur une table pour récupérer un sous-ensemble des partitions au lieu de charger toutes les partitions de la table. Pour en savoir plus sur l'utilisation des index de partition, consultez [Création d'index de partition](#).

Toutes les conditions suivantes doivent être remplies pour AWS Glue pour créer une table partitionnée pour un dossier Amazon S3 :

- Les schémas des fichiers sont similaires, tels que déterminés par AWS Glue.
- Le format de données des fichiers est le même.
- Le format de compression des fichiers est le même.

Par exemple, imaginons que vous possédez un compartiment Amazon S3 nommé `my-app-bucket`, où vous stockez des données de vente d'applications iOS et Android. Les données sont partitionnées par année, mois et jour. Les fichiers de données pour les ventes iOS et Android ont le même schéma, format de données et format de compression. Dans le AWS Glue Data Catalog, le AWS Glue crawler crée une définition de table avec des clés de partitionnement pour l'année, le mois et le jour.

La liste Amazon S3 `my-app-bucket` suivante présente certaines partitions. Le symbole `=` est utilisé pour attribuer des valeurs de clé de partition.

```
my-app-bucket/Sales/year=2010/month=feb/day=1/iOS.csv
my-app-bucket/Sales/year=2010/month=feb/day=1/Android.csv
my-app-bucket/Sales/year=2010/month=feb/day=2/iOS.csv
my-app-bucket/Sales/year=2010/month=feb/day=2/Android.csv
...
my-app-bucket/Sales/year=2017/month=feb/day=4/iOS.csv
my-app-bucket/Sales/year=2017/month=feb/day=4/Android.csv
```

Liens de ressources de table

Le AWS Glue la console a été récemment mise à jour. La version actuelle de la console ne prend pas en charge les liens de ressources de table.

Le catalogue de données peut également contenir des liens de ressources vers des tables. Un lien de ressource de table est un lien vers une table locale ou partagée. Actuellement, vous ne pouvez créer des liens de ressources que dans AWS Lake Formation. Après avoir créé un lien de ressource vers une table, vous pouvez utiliser le nom du lien de ressource partout où vous utiliseriez le nom de la table. Outre les tables que vous possédez ou qui sont partagées avec vous, les liens vers les ressources des tables sont renvoyés **glue:GetTables()** et apparaissent sous forme d'entrées sur la page Tables du AWS Glue console.

Le catalogue de données peut également contenir des liens de ressources de base de données.

Pour plus d'informations sur les liens de ressources, veuillez consulter la rubrique [Création de liens de ressources](#) dans le Guide du développeur AWS Lake Formation .

Création de tables à l'aide de la console

Un tableau figurant dans le AWS Glue Data Catalog est la définition des métadonnées qui représente les données d'un magasin de données. Vous créez des tables lorsque vous exécutez un crawler ; vous pouvez aussi créer une table manuellement dans la console AWS Glue . La liste des tables dans le AWS Glue la console affiche les valeurs des métadonnées de votre table. Les définitions de table vous permettent de spécifier des sources et des cibles lors de la création de tâches ETL (extraction, transformation et chargement).

Note

Avec les récentes modifications apportées à la console de AWS gestion, vous devrez peut-être modifier vos rôles IAM existants pour [SearchTables](#) obtenir l'autorisation. Pour la création de nouveaux rôles, l'autorisation d'API SearchTables a déjà été ajoutée par défaut.

Pour commencer, connectez-vous au AWS Management Console et ouvrez le AWS Glue console à <https://console.aws.amazon.com/glue/>. Choisissez l'onglet Tables et utilisez le bouton Add tables

(Ajouter des tables) pour créer des tables avec un crawler ou en saisissant manuellement les attributs.

Ajout de tableaux sur la console

Pour utiliser un crawler afin d'ajouter des tables, choisissez Add tables (Ajouter des tables), puis Add tables using a crawler (Ajouter des tables à l'aide d'un crawler). Ensuite, suivez les instructions fournies dans l'assistant Add crawler (Ajouter un crawler). Une fois que l'crawler s'exécute, les tables sont ajoutées à l' AWS Glue Data Catalog. Pour de plus amples informations, veuillez consulter [Utilisation de robots d'exploration pour alimenter le catalogue de données](#).

Si vous connaissez les attributs requis pour créer une définition de table Amazon Simple Storage Service (Amazon S3) dans votre Data Catalog, vous pouvez la créer avec l'assistant de table. Choisissez Add tables (Ajouter des tables), Add table manually (Ajouter une table manuellement), et suivez les instructions fournies dans l'assistant Add table (Ajouter une table).

Lors de l'ajout manuel d'une table à l'aide de la console, tenez compte des points suivants :

- Si vous prévoyez d'accéder à la table depuis Amazon Athena, fournissez un nom contenant uniquement des caractères alphanumériques et des traits de soulignement. Pour plus d'informations, consultez [Noms Athena](#).
- L'emplacement de vos données sources doit être un chemin d'accès Amazon S3.
- Le format des données doit correspondre à l'un des formats répertoriés dans l'assistant. La classification correspondante et SerDe les autres propriétés du tableau sont automatiquement renseignées en fonction du format choisi. Vous pouvez définir des tables aux formats suivants :

Avro

Format binaire JSON Apache Avro.

CSV

Valeurs séparées par des caractères. Vous pouvez également spécifier comme délimiteur une virgule, une barre verticale, un point-virgule, une tabulation ou Ctrl-A.

JSON

JavaScript Notation d'objets.

xml

Format XML (Extensible Markup Language). Spécifiez la balise XML qui définit une ligne dans les données. Les colonnes sont définies dans les balises de ligne.

Parquet

Stockage en colonnes Apache Parquet.

ORC

Format de fichier Optimized Row Columnar (ORC). Un format conçu pour stocker efficacement les données Hive.

- Vous pouvez définir une clé de partition pour la table.
- Actuellement, les tables partitionnées que vous créez avec la console ne peuvent pas être utilisées dans les tâches ETL.

Attributs des tables

Les attributs suivants font partie des plus importants de votre table :

Nom

Le nom est déterminé lorsque la table est créée, et vous ne pouvez pas le modifier. Vous faites référence à un nom de table dans de nombreux AWS Glue opérations.

Base de données

Objet conteneur dans lequel se trouve votre table. Cet objet contient une organisation de vos tables qui existe au sein de votre magasin de données AWS Glue Data Catalog et qui peut être différente de celle-ci. Lorsque vous supprimez une base de données, toutes les tables que celle-ci contient sont également supprimées de Data Catalog.

Description

Description de la table. Vous pouvez écrire une description vous aidant à comprendre le contenu de la table.

Format de table

Spécifiez la création d'une AWS Glue table standard ou d'une table au format Apache Iceberg.

Le catalogue de données fournit les options d'optimisation des tables suivantes pour gérer le stockage des tables et améliorer les performances des requêtes pour les tables Iceberg.

- **Compaction** : les fichiers de données sont fusionnés et réécrits pour supprimer les données obsolètes et consolider les données fragmentées dans des fichiers plus volumineux et plus efficaces.

- Conservation des instantanés : les instantanés sont des versions horodatées d'une table Iceberg. Les configurations de conservation des instantanés permettent aux clients de définir la durée de conservation des instantanés et le nombre d'instantanés à conserver. La configuration d'un optimiseur de conservation des instantanés peut aider à gérer la charge de stockage en supprimant les anciens instantanés inutiles et leurs fichiers sous-jacents associés.
- Suppression de fichiers orphelins — Les fichiers orphelins sont des fichiers qui ne sont plus référencés par les métadonnées de la table Iceberg. Ces fichiers peuvent s'accumuler au fil du temps, en particulier après des opérations telles que la suppression de tables ou l'échec de tâches ETL. L'activation de la suppression des fichiers orphelins permet AWS Glue d'identifier et de supprimer périodiquement ces fichiers inutiles, libérant ainsi de l'espace de stockage.

Pour de plus amples informations, veuillez consulter [Optimisation des tables Iceberg](#).

Configuration d'optimisation

Vous pouvez utiliser les paramètres par défaut ou personnaliser les paramètres pour activer les optimiseurs de table.

Rôle IAM

Pour exécuter les optimiseurs de table, le service assume un rôle IAM en votre nom. Vous pouvez choisir un rôle IAM à l'aide de la liste déroulante. Assurez-vous que le rôle dispose des autorisations requises pour activer le compactage.

Pour en savoir plus sur les autorisations requises pour le rôle IAM, consultez [Conditions préalables requises pour l'optimisation des tables](#).

Emplacement

Pointeur de l'emplacement des données dans un magasin de données que cette définition de table représente.

Classification

Valeur de catégorie fournie lors de la création de la table. En général, elle est écrite lors de l'exécution d'un crawler et spécifie le format de la source des données.

Dernière mise à jour

Date et heure (UTC) auxquelles cette table a été mise à jour dans Data Catalog.

Date ajoutée

Date et heure (UTC) auxquelles cette table a été ajoutée dans Data Catalog.

Obsolète

If AWS Glue découvre qu'une table du catalogue de données n'existe plus dans son magasin de données d'origine, il la marque comme obsolète dans le catalogue de données. Si vous exécutez une tâche qui fait référence à une table obsolète, la tâche peut échouer. Modifiez les tâches qui font référence à des tables obsolètes pour les supprimer en tant que sources et cibles. Nous vous recommandons de supprimer les tables obsolètes lorsqu'ils ne sont plus nécessaires.

Connexion

If AWS Glue nécessite une connexion à votre banque de données, le nom de la connexion est associé à la table.

Afficher et gérer les détails des tables

Pour afficher les détails d'une table existante, choisissez le nom de la table dans la liste, puis Action, View details (Action, Afficher les détails).

Les détails de la table comprennent les propriétés de votre table et son schéma. Cette vue affiche le schéma de la table, y compris les noms de colonnes dans l'ordre défini pour la table, les types de données et les colonnes de clés pour les partitions. Si une colonne est de type complexe, vous pouvez choisir View properties (Afficher les propriétés) pour afficher les détails de la structure de ce champ, comme illustré dans l'exemple suivant :

```
{
  "StorageDescriptor":
    {
      "cols": {
        "FieldSchema": [
          {
            "name": "primary-1",
            "type": "CHAR",
            "comment": ""
          },
          {
            "name": "second ",
            "type": "STRING",
            "comment": ""
          }
        ]
      }
    },
}
```

```
{
  "location": "s3://aws-logs-111122223333-us-east-1",
  "inputFormat": "",
  "outputFormat": "org.apache.hadoop.hive ql.io.HiveIgnoreKeyTextOutputFormat",
  "compressed": "false",
  "numBuckets": "0",
  "SerDeInfo": {
    "name": "",
    "serializationLib": "org.apache.hadoop.hive.serde2.OpenCSVSerde",
    "parameters": {
      "separatorChar": "|"
    }
  },
  "bucketCols": [],
  "sortCols": [],
  "parameters": {},
  "SkewedInfo": {},
  "storedAsSubDirectories": "false"
},
"parameters": {
  "classification": "csv"
}
}
```

Pour plus d'informations sur les propriétés d'une table, comme `StorageDescriptor`, consultez [StorageDescriptor structure](#).

Pour modifier le schéma d'une table, choisissez `Edit schema` (Modifier le schéma) pour ajouter et supprimer des colonnes, modifier les noms de colonnes et modifier les types de données.

Pour comparer différentes versions d'une table, y compris son schéma, choisissez `Comparer les versions` pour voir une side-by-side comparaison des deux versions du schéma d'une table. Pour de plus amples informations, veuillez consulter [Comparaison des versions de schéma de table](#).

Pour afficher les fichiers qui constituent une partition Amazon S3, sélectionnez `View partition` (Afficher la partition). Pour les tables Amazon S3, la colonne `Key` (Clé) affiche les clés de partition qui sont utilisées pour partitionner la table dans le magasin de données source. Le partitionnement permet de diviser une table en parties connexes en fonction des valeurs d'une colonne de clés, telles que la date, l'emplacement ou un service. Pour plus d'informations sur les partitions, effectuez une recherche sur Internet pour en savoir plus sur « le partitionnement Hive ».

Note


Pour obtenir step-by-step des conseils sur l'affichage des détails d'un tableau, consultez le didacticiel [Explore le tableau dans la console](#).

Comparaison des versions de schéma de table

Lorsque vous comparez deux versions de schémas de table, vous pouvez comparer les modifications des lignes imbriquées en développant et en réduisant les lignes imbriquées, comparer les schémas de deux versions et afficher les side-by-side propriétés des tables. side-by-side

Pour comparer les versions

1. À partir du AWS Glue console, choisissez Tables, puis Actions et sélectionnez Comparer les versions.



2. Choisissez une version à comparer en sélectionnant le menu déroulant des versions. Lorsque vous comparez des schémas, l'onglet Schéma est surligné en orange.
3. Lorsque vous comparez des tables entre deux versions, les schémas des tables s'affichent à gauche et à droite de l'écran. Cela vous permet de déterminer visuellement les modifications en comparant le nom de colonne, le type de données, la clé et les champs de commentaire side-by-side. En cas de modification, une icône colorée indique le type de modification apportée.
 - Supprimé : représenté par une icône rouge, indique l'endroit où la colonne a été supprimée d'une version précédente du schéma de table.
 - Modifié ou déplacé : représenté par une icône bleue, indique l'endroit où la colonne a été modifiée ou déplacée dans une version plus récente du schéma de table.
 - Ajouté : représenté par une icône verte, indique l'endroit où la colonne a été ajoutée à une version plus récente du schéma de table.
 - Modifications imbriquées : représentées par une icône jaune, indiquent où se trouvent les modifications dans la colonne imbriquée. Choisissez la colonne à développer et affichez les colonnes qui ont été supprimées, modifiées, déplacées ou ajoutées.

Compare versions: cloudtrail_data

Legend: Deleted Edited/Moved Added Nested Changes Deleted

Version 0 Last updated (UTC) January 17, 2023 at 19:08:58

Version 2 (Current version) Last updated (UTC) January 17, 2023 at 19:16:04

Schema Properties

Table fields (33)

Filter fields

Field name	Data type	Key	Comment
eventversion	string	-	-
useridentity	struct	-	-
eventtime	string	-	-
eventsource	string	-	-
eventname	string	-	-
awsregion	string	-	-
sourceipaddress	string	-	-
useragent	string	-	-
requestparameters	struct	-	-
bucketName	string	-	-
Host	string	-	-
acl	string	-	-
lookupAttributes	array	-	-
startTime	string	-	-
endTime	string	-	-
maxResults	int	-	-
nextToken	string	-	-
filter	struct	-	-
aggregateField	string	-	-
responseelements	string	-	-
additionalEventData	struct	-	-
requestid	string	-	-
eventid	string	-	-
readonly	boolean	-	-
resources	array	-	-
eventtype	string	-	-
managementevent	boolean	-	-
recipientaccountid	string	-	-
sharedeventid	string	-	-
eventcategory	string	-	-
sessioncredentialfromconsole	string	-	-
errorcode	string	-	-
errorMessage	string	-	-
new_col	string	-	-
eventid	string	(0)	-

- Utilisez la barre de recherche des champs de filtre pour afficher les champs en fonction des caractères que vous saisissez ici. Si vous saisissez un nom de colonne dans l'une ou l'autre des versions de table, les champs filtrés s'affichent dans les deux versions de la table pour vous indiquer l'emplacement des modifications.
- Pour comparer les propriétés, cliquez sur l'onglet Propriétés.
- Pour arrêter la comparaison des versions, choisissez Arrêter la comparaison pour revenir à la liste des tables.

Création d'index de partition

Au fil du temps, des centaines de milliers de partitions sont ajoutées à une table. L'[GetPartitions API](#) est utilisée pour récupérer les partitions de la table. L'API renvoie les partitions qui correspondent à l'expression fournie dans la demande.

Prenons l'exemple d'une table `sales_data` partitionnée par les clés `Country`, `Category`, `Year`, `Month` et `CreationDate`. Si vous souhaitez obtenir des données de vente pour tous les articles vendus dans la catégorie Livres en 2020 après le 15/08/2020, vous devez envoyer une *GetPartitions* demande au catalogue de données avec l'expression « `Category = 'Books'` et `CreationDate > '2020-08-15'` ».

Si aucun index de partition n'est présent sur la table, AWS Glue charge toutes les partitions de la table, puis filtre les partitions chargées à l'aide de l'expression de requête fournie par l'utilisateur dans la *GetPartitions* demande. L'exécution de la requête prend plus de temps à mesure que le nombre de partitions augmente sur une table sans index. Avec un index, la requête *GetPartitions* essaiera de récupérer un sous-ensemble des partitions au lieu de charger toutes les partitions de la table.

Rubriques

- [À propos des index de partition](#)
- [Création d'un tableau avec index de partition](#)
- [Ajout d'un index de partition à une table existante](#)
- [Description des indexes de partition sur une table](#)
- [Limitations de l'utilisation des index de partition](#)
- [Utilisation d'index pour un appel optimisé GetPartitions](#)
- [Intégration avec les moteurs](#)

À propos des index de partition

Lorsque vous créez un index de partition, vous spécifiez une liste de clés de partition qui existent déjà sur une table donnée. L'index de partition est une sous-liste des clés de partition définies dans la table. Un index de partition peut être créé sur n'importe quelle permutation de clés de partition définie sur la table. Pour la table `sales_data` ci-dessus, les index possibles sont (pays, catégorie, creationDate), (pays, catégorie, année), (pays, catégorie), (pays), (catégorie), (catégorie, pays, année, mois), etc.

Data Catalog concaténera les valeurs de partition dans l'ordre fourni au moment de la création de l'index. L'index est créé de manière cohérente à mesure que des partitions sont ajoutées à la table. Des index peuvent être créés pour les types de colonnes String (string, char et varchar), Numeric (int, bigint, long, tinyint et smallint) et Date (yyyy-mm-dd).

Types de données pris en charge

- Date — Une date au format ISO, telle que YYYY-MM-DD. Par exemple, date2020-08-15. Le format utilise des tirets (-) pour séparer l'année, le mois et le jour. La plage de dates autorisée pour l'indexation s'étend de à 0000-01-01. 9999-12-31
- String — Chaîne littérale entre guillemets simples ou doubles.
- Char — Données de caractères de longueur fixe, avec une longueur spécifiée comprise entre 1 et 255, telles que char (10).
- Varchar — Données de caractères de longueur variable, avec une longueur spécifiée comprise entre 1 et 65535, telles que varchar (10).
- Numérique — int, bigint, long, tinyint et smallint

Les index des types de données Numeric, String et Date prennent en charge les opérateurs =, >, >=, <, <= et entre les opérateurs. La solution d'indexation ne prend actuellement en charge que l'opérateur logique AND. Les sous-expressions avec les opérateurs « LIKE », « IN », « OR » et « NOT » sont ignorées dans l'expression pour le filtrage à l'aide d'un index. Le filtrage de la sous-expression ignorée est effectué sur les partitions récupérées après application du filtrage d'index.

Pour chaque partition ajoutée à une table, un élément d'index correspondant est créé. Pour une table avec 'n' partitions, 1 index de partition entraînera 'n' éléments d'index de partition. L'index de partition 'm' sur la même table se traduira par des éléments d'index de partition 'm*n'. Chaque élément de l'index de partition sera facturé en fonction du prix actuel AWS Glue politique tarifaire pour le stockage de catalogues de données. Pour plus de détails sur la tarification des objets de stockage, voir [AWS Glue tarification](#).

Création d'un tableau avec index de partition

Vous pouvez créer un index de partition lors de la création d'une table. La demande CreateTable prend une liste d'[objets PartitionIndex](#) comme entrée. 3 index de partition au maximum peuvent être créés sur une table donnée. Chaque index de partition nécessite un nom et une liste de partitionKeys définie pour la table. Les index créés sur une table peuvent être récupérés à l'aide de l'[API GetPartitionIndexes](#)

Ajout d'un index de partition à une table existante

Pour ajouter un index de partition à une table existante, utilisez l'opération `CreatePartitionIndex`. Vous pouvez créer un `PartitionIndex` par opération `CreatePartitionIndex`. L'ajout d'un index n'affecte pas la disponibilité d'une table, car la table reste disponible pendant la création des index.

L'état d'index d'une partition ajoutée est défini sur `CREATING` et la création des données d'index est lancée. Si le processus de création des index réussit, l'`indexStatus` est mis à jour sur `ACTIVE` et pour un processus infructueux, l'état de l'index est mis à jour sur `FAILED`. La création d'index peut échouer pour plusieurs raisons et vous pouvez utiliser l'opération `GetPartitionIndexes` pour récupérer les détails de l'échec. Les échecs possibles sont :

- `ENCRYPTED_PARTITION_ERROR` – la création d'index sur une table avec des partitions chiffrées n'est pas prise en charge.
- `INVALID_PARTITION_TYPE_DATA_ERROR` – observé lorsque la valeur `partitionKey` n'est pas une valeur valide pour le type de données `partitionKey` correspondant. Par exemple : un `partitionKey` avec le type de données 'int' a une valeur 'foo'.
- `MISSING_PARTITION_VALUE_ERROR` – observé lorsque le `partitionValue` pour un `indexedKey` est absent. Cela peut se produire lorsqu'une table n'est pas partitionnée de manière cohérente.
- `UNSUPPORTED_PARTITION_CHARACTER_ERROR` – observé lorsque la valeur d'une clé de partition indexée contient les caractères `\u0000`, `\u0001` ou `\u0002`.
- `INTERNAL_ERROR` – une erreur interne s'est produite lors de la création des index.

Description des indexes de partition sur une table

Pour extraire les index de partition créés sur une table, utilisez l'opération `GetPartitionIndexes`. La réponse renvoie tous les index de la table, ainsi que le statut actuel de chaque index (`IndexStatus`).

Le `IndexStatus` pour un index de partition sera l'un des suivants :

- `CREATING` – l'index est en cours de création et n'est pas encore disponible pour utilisation.
- `ACTIVE` – l'index est prêt à l'emploi. Les requêtes peuvent utiliser l'index pour effectuer une requête optimisée.

- **DELETING** – l'index est actuellement en cours de suppression et ne peut plus être utilisé. Un index à l'état actif peut être supprimé à l'aide de la demande `DeletePartitionIndex`, qui fait passer l'état de **ACTIVE** à **DELETING**.
- **FAILED** – échec de la création d'index sur une table existante. Chaque table stocke les 10 derniers index ayant échoué.

Les transitions d'état possibles pour les index créés sur une table existante sont :

- **CREATING** → **ACTIVE** → **DELETING**
- **CREATING** → **FAILED**

Limitations de l'utilisation des index de partition

Une fois que vous avez créé un index de partition, notez ces modifications apportées aux fonctionnalités de table et de partition :

Création d'une nouvelle partition (après ajout d'index)

Une fois qu'un index de partition est créé sur une table, toutes les nouvelles partitions ajoutées à la table seront validées pour les vérifications de type de données pour les clés indexées. La valeur de partition des clés indexées sera validée pour le format de type de données. Si la vérification du type de données échoue, l'opération de création de partition échouera. Pour la table `sales_data`, si un index est créé pour les clés (`category`, `year`) où la catégorie est de type `string` et l'année de type `int`, la création de la nouvelle partition avec une valeur de `YEAR` telle que "foo" échouera.

Une fois les index activés, l'ajout de partitions avec des valeurs de clé indexées ayant les caractères `U+0000`, `U+00001` et `U+0002` commencera à échouer.

mises à jour du tableau

Une fois qu'un index de partition est créé sur une table, vous ne pouvez pas modifier les noms de clé de partition pour les clés de partition existantes, et vous ne pouvez pas changer le type ou l'ordre des clés qui sont enregistrées avec l'index.

Utilisation d'index pour un appel optimisé `GetPartitions`

Lorsque vous appelez `GetPartitions` une table avec un index, vous pouvez inclure une expression et, le cas échéant, Data Catalog utilisera un index si possible. La première clé de

l'index doit être passée dans l'expression pour les index à utiliser dans le filtrage. L'optimisation de l'index dans le filtrage est appliquée au mieux. Data Catalog essaie d'utiliser l'optimisation d'index autant que possible, mais en cas d'index manquant ou d'opérateur non pris en charge, il revient à l'implémentation existante de chargement de toutes les partitions.

Pour la table `sales_data` ci-dessus, ajoutons l'index `[Country, Category, Year]`. Si « Country » (Pays) n'est pas passé dans l'expression, l'index enregistré ne pourra pas filtrer les partitions à l'aide d'index. Vous pouvez ajouter jusqu'à 3 index pour prendre en charge divers modèles de requête.

Prenons quelques exemples d'expressions et voyons comment les index fonctionnent dessus :

Expressions	Comment l'index sera-t-il utilisé
Country = 'US'	Index sera utilisé pour filtrer les partitions.
Country = 'US' and Category = 'Shoes'	Index sera utilisé pour filtrer les partitions.
Category = 'Shoes'	Les index ne seront pas utilisés car la valeur « country » (pays) n'est pas fourni dans l'expression. Toutes les partitions seront chargées pour renvoyer une réponse.
Country = 'US' and Category = 'Shoes' and Year > '2018'	Index sera utilisé pour filtrer les partitions.
Country = 'US' and Category = 'Shoes' and Year > '2018' and month = 2	L'index sera utilisé pour récupérer toutes les partitions avec pays = "US" and category = "shoes" and year > 2018. Ensuite, le filtrage sur l'expression du mois sera effectué.
Country = 'US' AND Category = 'Shoes' OR Year > '2018'	Les index ne seront pas utilisés, car un opérateur OR est présent dans l'expression.
Country = 'US' AND Category = 'Shoes' AND (Year = 2017 OR Year = '2018')	Index sera utilisé pour récupérer toutes les partitions avec country = "US" and category = "shoes", puis un filtrage sur l'expression de l'année sera effectué.

Expressions	Comment l'index sera-t-il utilisé
Country in ('US', 'UK') AND Category = 'Shoes'	Les index ne seront pas utilisés pour le filtrage, car l'opérateur IN n'est pas pris en charge actuellement.
Country = 'US' AND Category in ('Shoes', 'Books')	L'index sera utilisé pour récupérer toutes les partitions avec country = "US", puis un filtrage sur l'expression Category sera effectué.
Pays = « États-Unis » ET catégorie dans (« Chaussures », « Livres ») ET (CreationDate > « 2023-9-01 »)	L'index sera utilisé pour récupérer toutes les partitions avec country = « US », avec CreationDate > '2023-9-01', puis un filtrage sur l'expression Category sera effectué.

Intégration avec les moteurs

Redshift Spectrum, Amazon EMR et AWS Glue ETL Spark DataFrames est capable d'utiliser des index pour récupérer des partitions une fois que les index sont dans un état ACTIF dans AWS Glue. [Athéna](#) et [AWS Glue Les cadres dynamiques ETL vous](#) obligent à suivre des étapes supplémentaires pour utiliser les index afin d'améliorer les requêtes.

Activer le filtrage des partitions

Pour activer le filtrage des partitions dans Athena, vous devez mettre à jour les propriétés de la table comme suit :

1. Dans la AWS Glue console, sous Catalogue de données, sélectionnez Tables.
2. Choisissez une table .
3. Sous Actions, choisissez Modifier le tableau.
4. Sous Propriétés de la table, ajoutez ce qui suit :
 - Clé — `partition_filtering.enabled`
 - Valeur — `true`
5. Choisissez Appliquer.

Vous pouvez également définir ce paramètre en exécutant une requête [ALTER TABLE SET PROPERTIES](#) dans Athena.

```
ALTER TABLE partition_index.table_with_index  
SET TBLPROPERTIES ('partition_filtering.enabled' = 'true')
```

Mise à jour de tables Data Catalog créées manuellement à l'aide d'crawlers

Vous souhaitez peut-être créer des AWS Glue Data Catalog tables manuellement, puis les mettre à jour avec AWS Glue chenilles. Les crawlers respectant un calendrier peuvent ajouter de nouvelles partitions et mettre à jour les tables avec des modifications de schéma. Cela s'applique également aux tables migrées depuis un métastore Apache Hive.

Pour ce faire, lorsque vous définissez un crawler, au lieu de spécifier un ou plusieurs magasins de données en tant que source d'une analyse, vous spécifiez une ou plusieurs tables Data Catalog existantes. L'crawler analyse ensuite les magasins de données spécifiés par les tables du catalogue. Dans ce cas, aucune nouvelle table n'est créée ; au lieu de cela, vos tables créées manuellement sont mises à jour.

Voici d'autres raisons qui peuvent vous amener à vouloir créer manuellement des tables de catalogue et spécifier les tables de catalogue en tant qu'crawler source :

- Vous voulez choisir le nom de la table de catalogue et de ne pas vous fier à l'algorithme d'attribution de noms de la table de catalogue.
- Vous souhaitez empêcher de nouvelles tables d'être créées au cas où des fichiers dont le format pourrait perturber la détection de partition soient enregistrés par erreur dans le chemin de la source de données.

Pour de plus amples informations, veuillez consulter [Étape 2 : Choisir des sources de données et des classificateurs.](#)

Propriétés de la table Catalogue de données

Les propriétés de table, ou paramètres, comme on les appelle dans la AWS CLI, sont des chaînes de clés et de valeurs non validées. Vous pouvez définir vos propres propriétés sur la table pour prendre en charge les utilisations du Catalogue de données en dehors d' AWS Glue. D'autres services utilisant le catalogue de données peuvent également le faire. AWS Glue définit certaines propriétés de table lors de l'exécution de jobs ou de robots d'exploration. Sauf indication contraire, ces propriétés sont destinées à un usage interne. Nous ne garantissons pas le fait qu'elles continueront d'exister sous leur forme actuelle, et nous ne garantissons pas le comportement du produit si ces propriétés sont modifiées manuellement.

Pour plus d'informations sur les propriétés de table définies par AWS Glue les robots d'exploration, consultez [the section called “Paramètres définis sur les tables du Catalogue de données par un Crawler”](#).

Intégration à d'autres AWS services

Bien que vous puissiez utiliser AWS Glue crawler s pour remplir le catalogue AWS Glue Data Catalog, plusieurs AWS services peuvent automatiquement s'intégrer au catalogue et le remplir pour vous. Les sections suivantes fournissent des informations supplémentaires sur les cas d'utilisation spécifiques pris en charge par AWS les services qui peuvent alimenter le catalogue de données.

Rubriques

- [AWS Lake Formation](#)
- [Amazon Athena](#)

AWS Lake Formation

AWS Lake Formation est un service qui facilite la configuration d'un lac de données sécurisé dans AWS. Lake Formation est construite sur cette AWS Glue base, et Lake Formation et AWS Glue partage la même chose AWS Glue Data Catalog. Vous pouvez enregistrer l'emplacement de vos données Amazon S3 auprès de Lake Formation et utiliser la console Lake Formation pour créer des bases de données et des tables dans le catalogue de AWS Glue données, définir des politiques d'accès aux données et auditer l'accès aux données dans votre lac de données à partir d'un emplacement central. Vous pouvez utiliser le contrôle d'accès détaillé de Lake Formation pour gérer les ressources de votre catalogue de données existantes et les emplacements de données Amazon S3.

Avec les données enregistrées auprès de Lake Formation, vous pouvez partager en toute sécurité les ressources du catalogue de données entre les principaux responsables, les AWS comptes, les AWS organisations et les unités organisationnelles d'IAM.

Pour plus d'informations sur la création de ressources de catalogue de données à l'aide de Lake Formation, consultez la section [Création de tables et de bases de données de catalogue de données](#) dans le guide du AWS Lake Formation développeur.

Amazon Athena

Amazon Athena utilise le catalogue de données pour stocker et récupérer les métadonnées des tables correspondant aux données Amazon S3 de votre AWS compte. Les métadonnées de la table

permettent au moteur de requête Athena de savoir comment trouver, lire et traiter les données que vous souhaitez interroger.

Vous pouvez remplir le AWS Glue Data Catalog en utilisant directement les instructions `CREATE TABLE` Athena. Vous pouvez définir et renseigner manuellement le schéma et les métadonnées de partition dans le catalogue de données sans avoir à exécuter un robot d'exploration.

1. Dans la console Athena, créez une base de données qui stockera les métadonnées de la table dans le catalogue de données.
2. Utilisez l'`CREATE EXTERNAL TABLE` instruction pour définir le schéma de votre source de données.
3. Utilisez la `PARTITIONED BY` clause pour définir les clés de partition si vos données sont partitionnées.
4. Utilisez la `LOCATION` clause pour spécifier le chemin Amazon S3 où vos fichiers de données réels sont stockés.
5. Exécutez l'instruction `CREATE TABLE`.

Cette requête crée les métadonnées de table dans le catalogue de données en fonction du schéma et des partitions que vous avez définis, sans réellement analyser les données.

Vous pouvez interroger la table dans Athena, et elle utilisera les métadonnées du catalogue de données pour accéder à vos fichiers de données et les interroger dans Amazon S3.

Pour plus d'informations, consultez la section [Création de bases de données et de tables](#) dans le guide de l'utilisateur d'Amazon Athena.

Paramètres du catalogue de données

Les paramètres du catalogue de données contiennent des options permettant de définir les options de chiffrement et d'autorisation pour le catalogue de données de votre compte.

Last updated (UTC)
January 1, 1970 at 00:00:00

Encryption options

☐ Metadata encryption

Enable at-rest encryption for metadata stored in the data catalog.

☐ Encrypt connection passwords

When enabled, the password you provide when you create a connection is encrypted with the given KMS key.

Save

Pour modifier le contrôle d'accès détaillé du catalogue de données.

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Choisissez une option de chiffrement.
 - Chiffrement des métadonnées : cochez cette case pour chiffrer les métadonnées dans votre catalogue de données. Les métadonnées sont chiffrées au repos à l'aide de la clé AWS Key Management Service (AWS KMS) que vous spécifiez. Pour de plus amples informations, veuillez consulter [Chiffrement de votre catalogue de données](#).
 - Chiffrer les mots de passe de connexion : cochez cette case pour chiffrer les mots de passe dans le AWS Glue objet de connexion lorsque la connexion est créée ou mise à jour. Les mots de passe sont chiffrés à l'aide de la AWS KMS clé que vous spécifiez. Les mots de passe sont chiffrés lorsqu'ils sont renvoyés. Cette option est un paramètre global pour tous AWS Glue connexions dans le catalogue de données. Si vous décochez cette case, les mots de passe précédemment chiffrés le resteront selon une clé utilisée lors de leur création ou de leur mise à jour. Pour plus d'informations sur AWS Glue connexions, voir [Connexion aux données](#).

Lorsque vous activez cette option, choisissez une AWS KMS clé ou choisissez Enter a key ARN et fournissez le Amazon Resource Name (ARN) pour la clé. Entrez l'ARN sous la forme `arn:aws:kms:region:account-id:key/key-id` . Vous pouvez également fournir l'ARN sous la forme d'un alias de clé, (par exemple, `arn:aws:kms:region:account-id:alias/alias-name`).

 Important

Si cette option est sélectionnée, tout utilisateur ou rôle qui crée ou met à jour une connexion doit dispose d'une autorisation `kms:Encrypt` sur la clé KMS spécifiée.

Pour de plus amples informations, veuillez consulter [Chiffrement des mots de passe de connexion](#).

3. Sélectionnez Settings (Paramètres), puis dans l'éditeur Permissions (Autorisations), ajoutez l'instruction de politique pour modifier le contrôle d'accès détaillé du catalogue de données pour votre compte. Une seule politique peut être attachée à un catalogue de données à la fois. Vous pouvez coller une politique ressource JSON dans ce contrôle. Pour de plus amples informations, veuillez consulter [Politiques basées sur les ressources au sein de Glue AWS](#).

4. Sélectionnez Enregistrer pour mettre à jour le catalogue de données avec les modifications que vous avez apportées.

Vous pouvez également utiliser AWS Glue Opérations d'API pour mettre, obtenir et supprimer des politiques de ressources. Pour de plus amples informations, veuillez consulter [Sécurité APIs dans AWS Glue](#).

Remplissage et gestion des tables transactionnelles

[Apache Iceberg](#), [Apache Hudi](#) et Linux Foundation [Delta Lake](#) sont des formats de table open source conçus pour gérer les analyses de données à grande échelle et les charges de travail des lacs de données dans Apache Spark.

Vous pouvez remplir les tables Iceberg, Hudi et Delta Lake à l' AWS Glue Data Catalog aide des méthodes suivantes :

- AWS Glue crawler; — AWS Glue crawler s peut automatiquement découvrir et renseigner les métadonnées des tables Iceberg, Hudi et Delta Lake dans le catalogue de données. Pour de plus amples informations, veuillez consulter [Utilisation de robots d'exploration pour alimenter le catalogue de données](#) .
- AWS Glue Tâches ETL : vous pouvez créer des tâches ETL pour écrire des données dans les tables Iceberg, Hudi et Delta Lake et renseigner leurs métadonnées dans le catalogue de données. Pour plus d'informations, consultez la section [Utilisation de frameworks de lacs de données avec des tâches AWS Glue ETL](#).
- AWS Glue console, AWS Lake Formation console AWS CLI ou API : vous pouvez utiliser la AWS Glue console, la console Lake Formation ou l'API pour créer et gérer les définitions de tables Iceberg dans le catalogue de données.

Rubriques

- [Création de tables Apache Iceberg](#)
- [Optimisation des tables Iceberg](#)
- [Optimisation des performances des requêtes pour les tables Iceberg](#)

Création de tables Apache Iceberg

Vous pouvez créer des tables Apache Iceberg qui utilisent le format de données Apache Parquet AWS Glue Data Catalog avec des données résidant dans Amazon S3. Une table du catalogue de données est la définition des métadonnées qui représente les données d'un magasin de données. Par défaut, AWS Glue crée des tables Iceberg v2. Pour connaître la différence entre les tables v1 et v2, consultez la section [Modifications de version de format](#) dans la documentation Apache Iceberg.

[Apache Iceberg](#) est un format de table ouvert pour les jeux de données analytiques très volumineux. Iceberg permet de modifier facilement votre schéma, également connu sous le nom d'évolution du schéma, ce qui signifie que les utilisateurs peuvent ajouter, renommer ou supprimer des colonnes d'une table de données sans perturber les données sous-jacentes. Iceberg fournit également un support pour le versionnement des données, ce qui permet aux utilisateurs de suivre les modifications apportées aux données au fil du temps. Cela active la fonction de voyage dans le temps, qui permet aux utilisateurs d'accéder aux versions historiques des données, de les interroger et d'analyser les modifications apportées aux données entre les mises à jour et les suppressions.

Vous pouvez utiliser AWS Glue la console Lake Formation ou l'`CreateTable` opération de l' AWS Glue API pour créer une table Iceberg dans le catalogue de données. Pour plus d'informations, consultez [CreateTable action \(Python : create_table\)](#).

Lorsque vous créez une table Iceberg dans le catalogue de données, vous devez spécifier le format de la table et le chemin du fichier de métadonnées dans Amazon S3 pour pouvoir effectuer des lectures et des écritures.

Vous pouvez utiliser Lake Formation pour sécuriser votre table Iceberg à l'aide d'autorisations de contrôle d'accès précises lorsque vous enregistrez l'emplacement des données Amazon S3 auprès de celui-ci. AWS Lake Formation Pour les données source dans Amazon S3 et les métadonnées qui ne sont pas enregistrées auprès de Lake Formation, l'accès est déterminé par les politiques d'autorisation IAM pour Amazon S3 et AWS Glue les actions. Pour plus d'informations, consultez [la section Gestion des autorisations](#).

Note

Le catalogue de données ne prend pas en charge la création de partitions ni l'ajout de propriétés de table Iceberg.

Prérequis

Pour créer des tables Iceberg dans le catalogue de données et configurer les autorisations d'accès aux données de Lake Formation, vous devez remplir les conditions suivantes :

1. Autorisations requises pour créer des tables Iceberg sans les données enregistrées auprès de Lake Formation.

Outre les autorisations requises pour créer une table dans le catalogue de données, le créateur de la table doit disposer des autorisations suivantes :

- `s3:PutObject` sur la ressource `arn:aws:s3:::1 {bucketName}`
 - `s3:GetObject` sur la ressource `arn:aws:s3:::1 {bucketName}`
 - `s3:DeleteObject` sur la ressource `arn:aws:s3:::1 {bucketName}`
2. Autorisations requises pour créer des tables Iceberg avec des données enregistrées auprès de Lake Formation :

Pour utiliser Lake Formation afin de gérer et de sécuriser les données de votre lac de données, enregistrez votre site Amazon S3 contenant les données pour les tables auprès de Lake Formation. Cela permet à Lake Formation de vendre des informations d'identification à AWS des services d'analyse tels qu'Athena, Redshift Spectrum et Amazon EMR pour accéder aux données. Pour plus d'informations sur l'enregistrement d'un emplacement Amazon S3, consultez [Ajouter un emplacement Amazon S3 à votre lac de données](#).

Un directeur qui lit et écrit les données sous-jacentes enregistrées auprès de Lake Formation doit disposer des autorisations suivantes :

- `lakeformation:GetDataAccess`
- `DATA_LOCATION_ACCESS`

Un directeur qui possède des autorisations de localisation des données sur un emplacement possède également des autorisations de localisation sur tous les sites enfants.

Pour plus d'informations sur les autorisations de localisation des données, voir Ulink [sous-jacent pour le contrôle d'accès aux données](#).

Pour activer le compactage, le service doit assumer un rôle IAM autorisé à mettre à jour les tables dans le catalogue de données. Pour plus d'informations, consultez [Conditions préalables requises pour l'optimisation des tables](#).

Création d'une table Iceberg

Vous pouvez créer des tables Iceberg v1 et v2 à l'aide AWS Glue de la console Lake Formation ou AWS Command Line Interface comme indiqué sur cette page. Vous pouvez également créer des tables Iceberg à l'aide du AWS Glue crawler. Pour plus d'informations, consultez la section [Data Catalog and Crawlers](#) dans le manuel du AWS Glue développeur.

Pour créer une table Iceberg

Console

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Sous Catalogue de données, choisissez Tables, puis utilisez le bouton Créer une table pour spécifier les attributs suivants :
 - Nom de la table — Entrez le nom de la table. Si vous utilisez Athena pour accéder aux tables, suivez ces [conseils de dénomination](#) dans le guide de l'utilisateur d'Amazon Athena.
 - Base de données — Choisissez une base de données existante ou créez-en une nouvelle.
 - Description — Description de la table. Vous pouvez écrire une description vous aidant à comprendre le contenu de la table.
 - Format de tableau — Pour le format de tableau, choisissez Apache Iceberg.
 - Activer le compactage : sélectionnez Activer le compactage pour compacter les petits objets Amazon S3 du tableau en objets plus grands.
 - Rôle IAM : pour exécuter le compactage, le service assume un rôle IAM en votre nom. Vous pouvez choisir un rôle IAM à l'aide de la liste déroulante. Assurez-vous que le rôle dispose des autorisations requises pour activer le compactage.

Pour en savoir plus sur les autorisations requises, consultez [Conditions préalables requises pour l'optimisation des tables](#).

- Emplacement — Spécifiez le chemin d'accès au dossier dans Amazon S3 qui stocke la table de métadonnées. Iceberg a besoin d'un fichier de métadonnées et d'un emplacement dans le catalogue de données pour pouvoir effectuer des lectures et des écritures.

- Schéma — Choisissez Ajouter des colonnes pour ajouter des colonnes et les types de données des colonnes. Vous avez la possibilité de créer une table vide et de mettre à jour le schéma ultérieurement. Le catalogue de données prend en charge les types de données Hive. Pour plus d'informations, consultez la section [Types de données Hive](#).

Iceberg vous permet de faire évoluer le schéma et la partition après avoir créé la table. Vous pouvez utiliser les [requêtes Athena](#) pour mettre à jour le schéma de table et les [requêtes Spark](#) pour mettre à jour les partitions.

AWS CLI

```
aws glue create-table \  
  --database-name iceberg-db \  
  --region us-west-2 \  
  --open-table-format-input '{  
    "IcebergInput": {  
      "MetadataOperation": "CREATE",  
      "Version": "2"  
    }  
  }' \  
  --table-input '{"Name":"test-iceberg-input-demo",  
    "TableType": "EXTERNAL_TABLE",  
    "StorageDescriptor":{  
      "Columns":[  
        {"Name":"col1", "Type":"int"},  
        {"Name":"col2", "Type":"int"},  
        {"Name":"col3", "Type":"string"}  
      ],  
      "Location":"s3://DOC_EXAMPLE_BUCKET_ICEBERG/"  
    }  
  }'
```

Optimisation des tables Iceberg

AWS Glue prend en charge plusieurs options d'optimisation des tables afin d'améliorer la gestion et les performances des tables Apache Iceberg utilisées par les moteurs AWS d'analyse et les tâches ETL. Ces optimiseurs permettent d'utiliser efficacement le stockage, d'améliorer les performances

des requêtes et de gérer efficacement les données. Il existe trois types d'optimiseurs de table disponibles dans AWS Glue :

- **Compaction** : le compactage des données compacte les petits fichiers de données afin de réduire l'utilisation du stockage et d'améliorer les performances de lecture. Les fichiers de données sont fusionnés et réécrits pour supprimer les données obsolètes et consolider les données fragmentées dans des fichiers plus volumineux et plus efficaces. Vous pouvez configurer le compactage pour qu'il s'exécute automatiquement.

Binpack est la stratégie de compactage par défaut d'Apache Iceberg. Il combine des fichiers de données plus petits dans des fichiers plus volumineux pour des performances optimales. Le compactage prend également en charge les stratégies de tri et d'ordre Z qui regroupent des données similaires. Le tri organise les données en fonction de colonnes spécifiées, améliorant ainsi les performances des requêtes pour les opérations filtrées. L'ordre Z crée des ensembles de données triés qui améliorent les performances des requêtes lorsque plusieurs colonnes sont interrogées simultanément. Les trois stratégies de compactage (binpack, sort et ordre Z) réduisent la quantité de données numérisées par les moteurs de requêtes, réduisant ainsi les coûts de traitement des requêtes.

- **Conservation des instantanés** : les instantanés sont des versions horodatées d'une table Iceberg. Les configurations de conservation des instantanés permettent aux clients de définir la durée de conservation des instantanés et le nombre d'instantanés à conserver. La configuration d'un optimiseur de conservation des instantanés peut aider à gérer la charge de stockage en supprimant les anciens instantanés inutiles et leurs fichiers sous-jacents associés.
- **Suppression de fichiers orphelins** — Les fichiers orphelins sont des fichiers qui ne sont plus référencés par les métadonnées de la table Iceberg. Ces fichiers peuvent s'accumuler au fil du temps, en particulier après des opérations telles que la suppression de tables ou l'échec de tâches ETL. L'activation de la suppression des fichiers orphelins permet AWS Glue d'identifier et de supprimer périodiquement ces fichiers inutiles, libérant ainsi de l'espace de stockage.

Vous pouvez activer ou désactiver le compactage, la conservation des instantanés et les optimiseurs de suppression de fichiers orphelins pour les tables Iceberg individuelles du catalogue de données à l'aide de la AWS Glue console ou des opérations de l'API AWS CLI. AWS Glue

Rubriques

- [Conditions préalables requises pour l'optimisation des tables](#)
- [Optimisation du compactage](#)

- [Optimisation de la conservation des captures](#)
- [Supprimer des fichiers orphelins](#)
- [Afficher les détails de l'optimisation](#)
- [Afficher Amazon CloudWatch les métriques](#)
- [Suppression d'un optimiseur](#)
- [Considérations et restrictions](#)
- [Régions prises en charge pour les optimiseurs de tables](#)

Conditions préalables requises pour l'optimisation des tables

L'optimiseur de table utilise les autorisations du rôle AWS Identity and Access Management (IAM) que vous spécifiez lorsque vous activez les options d'optimisation (compactage, conservation des instantanés et suppression de fichiers orphelins) pour une table. Vous pouvez soit créer un rôle unique pour tous les optimiseurs, soit créer des rôles distincts pour chaque optimiseur.

Note

L'optimiseur de suppression de fichiers orphelins ne nécessite pas les autorisations `glue:updateTable` or `s3:putObject`. Les optimiseurs d'expiration et de compactage des instantanés nécessitent le même ensemble d'autorisations.

Le rôle IAM doit être autorisé à lire les données et à mettre à jour les métadonnées dans le catalogue de données. Vous pouvez créer un rôle IAM et y attacher les stratégies en ligne suivantes :

- Ajoutez la politique en ligne suivante qui accorde à Amazon S3 des autorisations de lecture/écriture sur l'emplacement pour les données qui ne sont pas enregistrées auprès de celui-ci. AWS Lake Formation Cette politique inclut également des autorisations pour mettre à jour le tableau dans le catalogue de données, ainsi que AWS Glue pour autoriser l'ajout de journaux dans les Amazon CloudWatch journaux et la publication de métriques. Pour les données sources dans Amazon S3 qui ne sont pas enregistrées auprès de Lake Formation, l'accès est déterminé par les stratégies d'autorisation IAM pour Amazon S3 et les actions AWS Glue .

Dans les stratégies en ligne suivantes, remplacez le `bucket-name` par le nom de votre compartiment Amazon S3, `aws-account-id` et `region` par un numéro valide du compte AWS

et une région du catalogue de données, `database_name` par le nom de votre base de données et `table_name` par le nom de la table.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:PutObject",
        "s3:GetObject",
        "s3:DeleteObject"
      ],
      "Resource": [
        "arn:aws:s3:::<bucket-name>/*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "s3:ListBucket"
      ],
      "Resource": [
        "arn:aws:s3:::<bucket-name>"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "glue:UpdateTable",
        "glue:GetTable"
      ],
      "Resource": [
        "arn:aws:glue:<region>:<aws-account-id>:table/<database-name>/<table-
name>",
        "arn:aws:glue:<region>:<aws-account-id>:database/<database-name>",
        "arn:aws:glue:<region>:<aws-account-id>:catalog"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
```

```

        "logs:CreateLogStream",
        "logs:PutLogEvents"
    ],
    "Resource": [
        "arn:aws:logs:<region>:<aws-account-id>:log-group:/aws-glue/iceberg-
compaction/logs:*",
        "arn:aws:logs:<region>:<aws-account-id>:log-group:/aws-glue/iceberg-
retention/logs:*",
        "arn:aws:logs:<region>:<aws-account-id>:log-group:/aws-glue/iceberg-
orphan-file-deletion/logs:*"
    ]
}

```

- Utilisez la stratégie suivante pour activer le compactage des données enregistrées auprès de Lake Formation.

Si le rôle d'optimisation ne dispose pas d'autorisations de IAM_ALLOWED_PRINCIPALS groupe accordées sur la table, le rôle nécessite Lake Formation ALTER INSERT et DELETE des autorisations sur la table. DESCRIBE

Pour plus d'informations sur l'enregistrement d'un bucket Amazon S3 auprès de Lake Formation, consultez [Ajouter un emplacement Amazon S3 à votre lac de données](#).

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lakeformation:GetDataAccess"
      ],
      "Resource": "*"
    },
    {
      "Effect": "Allow",
      "Action": [
        "glue:UpdateTable",
        "glue:GetTable"
      ],
      "Resource": [

```

```

        "arn:aws:glue:<region>:<aws-account-id>:table/<databaseName>/<tableName>",
        "arn:aws:glue:<region>:<aws-account-id>:database/<database-name>",
        "arn:aws:glue:<region>:<aws-account-id>:catalog"
    ],
},
{
    "Effect": "Allow",
    "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
    ],
    "Resource": [
        "arn:aws:logs:<region>:<aws-account-id>:log-group:/aws-glue/iceberg-compaction/logs:*",
        "arn:aws:logs:<region>:<aws-account-id>:log-group:/aws-glue/iceberg-retention/logs:*",
        "arn:aws:logs:<region>:<aws-account-id>:log-group:/aws-glue/iceberg-orphan-file-deletion/logs:*"
    ]
}
}

```

- (Facultatif) Pour optimiser les tables Iceberg avec les données des compartiments Amazon S3 chiffrées à l'aide du [chiffrement côté serveur](#), le rôle de compactage nécessite des autorisations pour déchiffrer les objets Amazon S3 et générer une nouvelle clé de données pour écrire des objets dans les compartiments chiffrés. Ajoutez la politique suivante à la AWS KMS clé souhaitée. Nous prenons uniquement en charge le chiffrement au niveau du compartiment.

```

{
    "Effect": "Allow",
    "Principal": {
        "AWS": "arn:aws:iam::<aws-account-id>:role/<optimizer-role-name>"
    },
    "Action": [
        "kms:Decrypt",
        "kms:GenerateDataKey"
    ],
    "Resource": "*"
}

```

- (Facultatif) Pour l'emplacement des données enregistré auprès de Lake Formation, le rôle utilisé pour enregistrer l'emplacement nécessite des autorisations pour déchiffrer les objets Amazon S3 et générer une nouvelle clé de données pour écrire des objets dans les compartiments chiffrés. Pour plus d'informations, consultez la rubrique [Enregistrement d'un emplacement Amazon S3 chiffré](#).
- (Facultatif) Si la AWS KMS clé est stockée dans un autre AWS compte, vous devez inclure les autorisations suivantes pour le rôle de compactage.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "kms:Decrypt",
        "kms:GenerateDataKey"
      ],
      "Resource": ["arn:aws:kms:<REGION>:<KEY_OWNER_ACCOUNT_ID>:key/<KEY_ID>" ]
    }
  ]
}
```

- Le rôle que vous utilisez pour exécuter le compactage doit disposer de l'autorisation `iam:PassRole` correspondante.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "iam:PassRole"
      ],
      "Resource": [
        "arn:aws:iam::<account-id>:role/<optimizer-role-name>"
      ]
    }
  ]
}
```

- Ajoutez la politique de confiance suivante au rôle afin que le AWS Glue service assume le rôle IAM pour exécuter le processus de compactage.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "",
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

Optimisation du compactage

Les lacs de données Amazon S3 utilisant des formats de table ouverts tels qu'Apache Iceberg stockent les données sous forme d'objets S3. La présence de milliers de petits objets Amazon S3 dans une table de lac de données augmente la surcharge de métadonnées et affecte les performances de lecture. AWS Glue Data Catalog fournit un compactage géré pour les tables Iceberg, en compactant de petits objets en de plus grands objets pour améliorer les performances de lecture grâce à des services AWS d'analyse tels qu' Amazon Athena Amazon EMR et à des tâches ETL. AWS Glue Data Catalog effectue le compactage sans interférer avec les requêtes simultanées et prend en charge le compactage uniquement pour les tables au format Parquet.

L'optimiseur de table surveille en permanence les partitions des tables et lance le processus de compactage lorsque le seuil est dépassé pour le nombre de fichiers et leur taille.

Dans le catalogue de données, le processus de compactage démarre lorsqu'une table ou l'une de ses partitions contient plus de 100 fichiers. Chaque fichier doit être inférieur à 75 % de la taille du fichier cible. La taille du fichier cible est définie par la propriété `write.target-file-size-bytes` table, qui est par défaut de 512 Mo si elle n'est pas définie explicitement.

Pour connaître les limitations, veuillez consulter [Formats pris en charge et limites pour le compactage géré des données](#).

Rubriques

- [Activation de l'optimiseur de compactage](#)
- [Désactivation de l'optimiseur de compactage](#)

Activation de l'optimiseur de compactage

Vous pouvez utiliser AWS Glue la console ou l' AWS API pour activer le compactage de vos tables Apache Iceberg dans le catalogue de AWS Glue données. AWS CLI Pour les nouvelles tables, vous pouvez choisir Apache Iceberg comme format de table et activer le compactage lors de la création de la table. Le compactage est désactivé par défaut pour les nouvelles tables.

Console

Pour activer le compactage

1. Ouvrez la AWS Glue console <https://console.aws.amazon.com/glue/> et connectez-vous en tant qu'administrateur du lac de données, créateur de table ou utilisateur ayant obtenu les `lakeformation:GetDataAccess` autorisations `glue:UpdateTable` et sur la table.
2. Dans le panneau de navigation, sous Catalogue de données, choisissez Tables.
3. Sur la page Tables, choisissez une table au format de table ouverte pour laquelle vous souhaitez activer le compactage, puis dans le menu Actions, choisissez Optimisation, puis sélectionnez Activer.

Vous pouvez également activer le compactage en sélectionnant l'onglet Optimisation des tables sur la page des détails des tables. Choisissez l'onglet Optimisation des tables dans la partie inférieure de la page, puis sélectionnez Activer le compactage.

L'option Activer l'optimisation est également disponible lorsque vous créez une nouvelle table Iceberg dans le catalogue de données.

4. Sur la page Activer l'optimisation, sélectionnez Compaction sous Options d'optimisation.

Enable optimization

Enable table optimizers for managed tables in the Data Catalog to optimize storage and improve query performance. [View pricing](#)

Optimization options

Table optimization

☒ Compaction

Combine small data files into larger, more efficient files to optimize table performance.

☐ Snapshot retention - *new*

Optimize table storage by removing old snapshots from metadata overhead and expiring files that are no longer needed.

☐ Orphan file deletion - *new*

Automatically clean up orphan files periodically.

Optimization configuration

Configure Apache Iceberg table optimization to optimize storage and improve query performances. [Learn more](#)

☐ Use default settings

Default settings have been defined to help you get started. You can change them at any time later.

☒ Customize settings

Customize settings for your specific needs.

IAM Role

Configure for all selected optimizers.

☒ Apply the selected IAM role to all selected optimizers. Update individual roles later as needed.

Create a single role with necessary permissions to configure all table optimizers. [Learn more](#)

IAM role

AWSGlueServiceRoleDefault



[View](#)

[Create new IAM role](#)

Virtual private cloud (VPC) - *optional*

Choose a network connection to access a data store in your VPC.

[Choose a Glue connection](#)

[Create Glue network connection](#)

Compaction configuration

Compaction strategy

Apache Iceberg supports 3 distinct compaction strategies. [Learn more](#)

☒ Binpack

Apache Iceberg uses binpack to compact data files into larger files. This strategy is the default and recommended for most use cases.

☐ Sort

Sort is a technique for clustering data within files based on specified columns. To use this strategy, you must first define a sort order in your Iceberg table properties using the 'sort_order' table property.

☐ Z-Order

Z-order is a technique that maps multi-dimensional data to a single dimension by interleaving the binary representation of the values in the columns. To use this strategy, you must first define the columns to be z-ordered in your Iceberg table properties using the 'sort_order' table property.

[Cancel](#)

[Enable optimization](#)

5. Ensuite, sélectionnez un rôle IAM dans le menu déroulant avec les autorisations indiquées dans la [Conditions préalables requises pour l'optimisation des tables](#) section.

Vous pouvez également choisir l'option Créer un nouveau rôle IAM pour créer un rôle personnalisé doté des autorisations requises pour exécuter le compactage.

Suivez les étapes ci-dessous pour mettre à jour un rôle IAM existant :

- a. Pour mettre à jour la stratégie d'autorisation pour le rôle IAM, dans la console IAM, accédez au rôle IAM utilisé pour exécuter le compactage.
- b. Dans la section Ajouter des autorisations, choisissez Créer une politique. Dans la fenêtre du navigateur nouvellement ouverte, créez une nouvelle stratégie à utiliser avec votre rôle.
- c. Sur la page Créer une politique, choisissez l'JSONonglet. Copiez le code JSON affiché dans les conditions préalables dans le champ de l'éditeur de politiques.

6. Si vous avez des configurations de politique de sécurité dans lesquelles l'optimiseur de table Iceberg doit accéder aux compartiments Amazon S3 à partir d'un Virtual Private Cloud (VPC) spécifique, créez AWS Glue une connexion réseau ou utilisez une connexion réseau existante.

Si aucune connexion AWS Glue VPC n'est déjà configurée, créez-en une nouvelle en suivant les étapes de la section [Création de connexions pour les connecteurs](#) à l'aide de la AWS Glue console ou du /SDK. AWS CLI

7. Choisissez une stratégie de compactage. Les options disponibles sont les suivantes :
 - Binpack — Binpack est la stratégie de compactage par défaut dans Apache Iceberg. Il combine des fichiers de données plus petits dans des fichiers plus volumineux pour des performances optimales.
 - Tri : le tri dans Apache Iceberg est une technique d'organisation des données qui regroupe les informations au sein de fichiers en fonction de colonnes spécifiées, ce qui améliore considérablement les performances des requêtes en réduisant le nombre de fichiers à traiter. Vous définissez l'ordre de tri dans les métadonnées d'Iceberg à l'aide du champ d'ordre de tri, et lorsque plusieurs colonnes sont spécifiées, les données sont triées dans l'ordre dans lequel les colonnes apparaissent dans l'ordre de tri, ce qui garantit que les enregistrements présentant des valeurs similaires sont stockés ensemble dans des fichiers. La stratégie de tri et de compactage va plus loin dans l'optimisation en triant les données dans tous les fichiers d'une partition.
 - Ordre en Z — L'ordre en Z est un moyen d'organiser les données lorsque vous devez les trier selon plusieurs colonnes ayant la même importance. Contrairement au tri traditionnel qui donne la priorité à une colonne par rapport aux autres, l'ordre en Z donne une pondération équilibrée à chaque colonne, ce qui permet à votre moteur de requête de lire moins de fichiers lors de la recherche de données.

La technique fonctionne en combinant les chiffres binaires des valeurs de différentes colonnes. Par exemple, si vous avez les chiffres 3 et 4 sur deux colonnes, l'ordre Z les convertit d'abord en binaire (3 devient 011 et 4 devient 100), puis entrelace ces chiffres pour créer une nouvelle valeur : 011010. Cet entrelacement crée un modèle qui maintient les données associées physiquement proches les unes des autres.

Le classement en Z est particulièrement efficace pour les requêtes multidimensionnelles. Par exemple, une table de clients triée en Z par revenu, État et code postal peut offrir des performances supérieures à celles d'un tri hiérarchique lors d'une interrogation portant sur plusieurs dimensions. Cette organisation permet aux requêtes ciblant des combinaisons

spécifiques de revenus et de situation géographique de localiser rapidement les données pertinentes tout en minimisant les analyses de fichiers inutiles.

8. Choisissez Activer l'optimisation.

AWS CLI

L'exemple suivant montre comment activer le compactage. Remplacez l'identifiant de compte par un identifiant de AWS compte valide. Remplacez le nom de la base de données et le nom de la table par un nom réel de la table Iceberg et le nom de la base de données. Remplacez le `roleArn` par l'ARN (Amazon Resource Name) AWS du rôle IAM et le nom du rôle IAM qui dispose des autorisations requises pour exécuter le compactage. Vous pouvez remplacer la stratégie de compactage par sort d'autres stratégies prises en charge, telles que `z-order` ou `binpack`.

commander » en fonction de vos besoins.

```
aws glue create-table-optimizer \  
  --catalog-id 123456789012 \  
  --database-name iceberg_db \  
  --table-name iceberg_table \  
  --table-optimizer-configuration '{  
    "roleArn": "arn:aws:iam::123456789012:role/optimizer_role",  
    "enabled": true,  
    "vpcConfiguration": {"glueConnectionName": "glue_connection_name"},  
    "compactionConfiguration": {  
      "icebergConfiguration": {"strategy": "sort"}  
    }  
  }'\  
  --type compaction
```

AWS API

Appelez une opération [CreateTableOptimizer](#) pour activer le compactage d'une table.

Une fois le compactage activé, l'onglet Optimisation de la table affiche les détails de compactage suivants une fois le compactage terminé :

L'heure de début

Heure à laquelle le processus de compactage a commencé dans le catalogue de données. La valeur est un horodatage selon le fuseau UTC.

L'heure de fin

Heure à laquelle le processus de compactage s'est terminé dans le catalogue de données. La valeur est un horodatage selon le fuseau UTC.

Statut

État du cycle de compactage. Les valeurs sont la réussite ou l'échec.

Fichiers compactés

Nombre total de fichiers compactés.

Octets compactés

Nombre total d'octets compactés.

Désactivation de l'optimiseur de compactage

Vous pouvez désactiver le compactage automatique pour une table Apache Iceberg particulière à l'aide de AWS Glue la console ou. AWS CLI

Console

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le menu de navigation de gauche, sous Catalogue de données, sélectionnez Tables.
3. Dans la liste des tables, choisissez la table Iceberg pour laquelle vous souhaitez désactiver le compactage.
4. Choisissez l'onglet Optimisation des tables dans la section inférieure de la page des détails des tables.
5. Dans Actions, choisissez Désactiver, puis sélectionnez Compaction.
6. Choisissez Désactiver le compactage dans le message de confirmation. Vous pouvez réactiver le compactage ultérieurement.

Une fois que vous avez confirmé, le compactage est désactivé et l'état de compactage de la table revient à Disabled.

AWS CLI

Dans l'exemple suivant, remplacez l'ID de compte par un ID de AWS compte valide. Remplacez le nom de la base de données et le nom de la table par un nom réel de la table Iceberg et le nom de la base de données. Remplacez le `roleArn` par le nom de AWS ressource (ARN) du rôle IAM et le nom réel du rôle IAM disposant des autorisations requises pour exécuter le compactage.

```
aws glue update-table-optimizer \  
  --catalog-id 123456789012 \  
  --database-name iceberg_db \  
  --table-name iceberg_table \  
  --table-optimizer-configuration  
'{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role", "enabled":'false',  
  "vpcConfiguration":{"glueConnectionName":"glue_connection_name"}}'\  
  --type compaction
```

AWS API

Appelez l'opération [UpdateTableOptimizer](#) pour désactiver le compactage d'une table spécifique.

Optimisation de la conservation des captures

La fonctionnalité de conservation des instantanés d'Apache Iceberg permet aux utilisateurs d'interroger les données historiques à des moments précis et d'annuler les modifications indésirables apportées à leurs tables. Dans le catalogue de AWS Glue données, la configuration de conservation des instantanés contrôle la durée de conservation de ces instantanés (versions des données de table) avant leur expiration et leur suppression. Cela permet de gérer les coûts de stockage et la surcharge de métadonnées en supprimant automatiquement les anciens instantanés en fonction d'une période de conservation configurée ou du nombre maximal de clichés à conserver.

Vous pouvez configurer la période de conservation en jours et le nombre maximal de clichés à conserver pour une table. AWS Glue supprime les instantanés antérieurs à la période de rétention spécifiée des métadonnées de la table, tout en préservant les instantanés les plus récents dans les limites configurées. Après avoir supprimé les anciens instantanés des métadonnées, AWS Glue supprime les données et les fichiers de métadonnées correspondants qui ne sont plus référencés et uniques aux instantanés expirés. Cela permet aux requêtes de voyager dans le temps uniquement jusqu'aux instantanés conservés restants, tout en récupérant l'espace de stockage utilisé par les données de capture expirées.

Rubriques

- [Activation de l'optimiseur de conservation des instantanés](#)
- [Mettre à jour l'optimiseur de rétention des instantanés](#)
- [Désactivation de l'optimiseur de rétention des instantanés](#)

Activation de l'optimiseur de conservation des instantanés

Vous pouvez utiliser AWS Glue la console ou l' AWS API pour activer les optimiseurs de rétention des instantanés pour vos tables Apache Iceberg dans le catalogue de données. AWS CLI Pour les nouvelles tables, vous pouvez choisir Apache Iceberg comme format de table et activer l'optimiseur de conservation des instantanés lorsque vous créez la table. La conservation des instantanés est désactivée par défaut pour les nouvelles tables.

Console

Pour activer l'optimiseur de rétention des instantanés

1. Ouvrez la AWS Glue console <https://console.aws.amazon.com/glue/> et connectez-vous en tant qu'administrateur du lac de données, créateur de table ou utilisateur ayant obtenu les `lakeformation:GetDataAccess` autorisations `glue:UpdateTable` et sur la table.
2. Dans le panneau de navigation, sous Catalogue de données, choisissez Tables.
3. Sur la page Tables, choisissez une table Iceberg pour laquelle vous souhaitez activer l'optimiseur de conservation des instantanés, puis dans le menu Actions, choisissez Activer sous Optimisation.

Vous pouvez également activer l'optimisation en sélectionnant le tableau et en ouvrant la page des détails du tableau. Choisissez l'onglet Optimisation des tables dans la partie inférieure de la page, puis sélectionnez Activer la conservation des instantanés.

4. Sur la page Activer l'optimisation, sous Configuration de l'optimisation, vous avez deux options : Utiliser les paramètres par défaut ou Personnaliser les paramètres. Si vous choisissez d'utiliser les paramètres par défaut, AWS Glue utilise les propriétés définies dans la configuration de la table Iceberg pour déterminer la période de conservation des instantanés et le nombre de clichés à conserver. En l'absence de cette configuration, AWS Glue conserve un instantané pendant cinq jours et supprime les fichiers associés aux instantanés expirés.
5. Ensuite, choisissez un rôle IAM qui AWS Glue peut assumer en votre nom le rôle d'exécution de l'optimiseur. Pour plus de détails sur les autorisations requises pour le rôle IAM, consultez la [Conditions préalables requises pour l'optimisation des tables](#) section.

Suivez les étapes ci-dessous pour mettre à jour un rôle IAM existant :

- a. Pour mettre à jour la stratégie d'autorisation pour le rôle IAM, dans la console IAM, accédez au rôle IAM utilisé pour exécuter le compactage.
 - b. Dans la section Ajouter des autorisations, choisissez Créer une stratégie. Dans la fenêtre du navigateur nouvellement ouverte, créez une nouvelle stratégie à utiliser avec votre rôle.
 - c. Sur la page Créer une politique, choisissez l'onglet JSON. Copiez le code JSON affiché dans les conditions préalables dans le champ de l'éditeur de politiques.
6. Si vous préférez définir les valeurs de la configuration de conservation des instantanés manuellement, choisissez Personnaliser les paramètres.

Optimization configuration
Configure Apache Iceberg table optimization to optimize storage and improve query performances. [Learn more](#)

☐ Use default settings
Default settings have been defined to help you get started. You can change them at any time later.

☒ Customize settings
Customize settings for your specific needs.

IAM Role
Configure for all selected optimizers.

☒ Apply the selected IAM role to all selected optimizers. Update individual roles later as needed.
Create a single role with necessary permissions to configure all table optimizers. [Learn more](#)

IAM role
Admin [View](#)

[Create new IAM role](#)

Virtual private cloud (VPC) - optional
Choose a network connection to access a data store in your VPC.

[Create Glue network connection](#)

Snapshot retention configuration

Snapshot retention period
Configure how long Apache Iceberg retains historical table snapshots before deleting them.

☒ Use the value specified in Apache Iceberg table configuration
If no value is provided, use the default retention period of 5 days for snapshots.

☐ Specify a custom value in days

Minimum snapshot to retain

☒ Use the value specified in Apache Iceberg table configuration
If no value is provided, use the default setting of retaining one snapshot.

☐ Specify a custom value

Expired snapshots associated files

☒ Delete associated files
Files associated with the expired snapshots will be deleted.

Caution

- Snapshot retention optimizer will delete expired snapshot metadata. Additionally, data files for expired snapshots will be deleted unless you use the *Customize settings* pane and deselect the option to *Delete associated files*.

For more information, see [Optimizer considerations](#).

☐ I acknowledge that expired data will be deleted as part of the optimizers.

[Cancel](#) [Enable optimization](#)

7. Cochez la case Appliquer le rôle IAM sélectionné aux optimiseurs sélectionnés pour utiliser un seul rôle IAM pour tous en activant tous les optimiseurs.
8. Si vous avez des configurations de politique de sécurité dans lesquelles l'optimiseur de table Iceberg doit accéder aux compartiments Amazon S3 à partir d'un Virtual Private Cloud (VPC) spécifique, créez AWS Glue une connexion réseau ou utilisez une connexion réseau existante.

Si aucune connexion AWS Glue VPC n'est déjà configurée, créez-en une nouvelle en suivant les étapes de la section [Création de connexions pour les connecteurs](#) à l'aide de la AWS Glue console ou du /SDK. AWS CLI

9. Ensuite, sous Configuration de conservation des instantanés, choisissez d'utiliser les valeurs spécifiées dans la [configuration de la table Iceberg](#) ou de spécifier des valeurs personnalisées pour la période de conservation des instantanés (history.expire. max-snapshot-age-ms) et le nombre minimum de clichés (history.expire. min-snapshots-to-keep) à conserver.
10. Choisissez Supprimer les fichiers associés pour supprimer les fichiers sous-jacents lorsque l'optimiseur de table supprime les anciens instantanés des métadonnées de la table.

Si vous ne choisissez pas cette option, lorsque les anciens instantanés sont supprimés des métadonnées de la table, les fichiers associés resteront dans le stockage en tant que fichiers orphelins.

11. Ensuite, lisez la mise en garde, puis choisissez Je confirme pour continuer.

 Note

Dans le catalogue de données, l'optimiseur de rétention des instantanés respecte le cycle de vie contrôlé par les politiques de conservation au niveau des succursales et des balises. Pour plus d'informations, consultez la section [Branchement et balisage](#) de la documentation d'Iceberg.

12. Passez en revue la configuration et choisissez Activer l'optimisation.

Attendez quelques minutes que l'optimiseur de rétention s'exécute et que les anciens instantanés expirent en fonction de la configuration.

AWS CLI

Pour activer la conservation des instantanés pour les nouvelles tables Iceberg dans AWS Glue, vous devez créer un optimiseur de table de type retention et définir le enabled champ sur true dans le. table-optimizer-configuration Vous pouvez le faire à l'aide de la AWS CLI commande create-table-optimizer ou update-table-optimizer. En outre, vous devez spécifier les champs de configuration de rétention tels que snapshotRetentionPeriodInDays et numberOfSnapshotsToRetain en fonction de vos besoins.

L'exemple suivant montre comment activer l'optimiseur de rétention des instantanés. Remplacez l'identifiant de compte par un identifiant de AWS compte valide. Remplacez le nom de la base de données et le nom de la table par un nom réel de la table Iceberg et le nom de la base de données. Remplacez le `roleArn` par le nom de AWS ressource (ARN) du rôle IAM et le nom du rôle IAM disposant des autorisations requises pour exécuter l'optimiseur de rétention des instantanés.

```
aws glue create-table-optimizer \  
  --catalog-id 123456789012 \  
  --database-name iceberg_db \  
  --table-name iceberg_table \  
  --table-optimizer-configuration \  
  '{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role","enabled":"'true',  
  "vpcConfiguration":{  
  "glueConnectionName":"glue_connection_name"}, "retentionConfiguration":  
  {"icebergConfiguration":  
  {"snapshotRetentionPeriodInDays":7,"numberOfSnapshotsToRetain":3,"cleanExpiredFiles":"'true'"}  
  --type retention
```

Cette commande crée un optimiseur de rétention pour la table Iceberg spécifiée dans le catalogue, la base de données et la région donnés. `table-optimizer-configuration` Spécifie l'ARN du rôle IAM à utiliser, active l'optimiseur et définit la configuration de rétention. Dans cet exemple, il conserve les instantanés pendant 7 jours, conserve au moins 3 instantanés et nettoie les fichiers expirés.

- `snapshotRetentionPeriodInDays` : le nombre de jours pendant lesquels les instantanés sont conservés avant leur expiration. La valeur par défaut est 5.
- `numberOfSnapshotsToRetain` — Le nombre minimum de clichés à conserver, même s'ils sont antérieurs à la période de conservation. La valeur par défaut est 1.
- `cleanExpiredFiles` — Un booléen indiquant s'il faut supprimer les fichiers de données expirés après l'expiration des instantanés. La valeur par défaut est `true`.

Lorsque ce paramètre est défini sur `true`, les anciens instantanés sont supprimés des métadonnées de la table et leurs fichiers sous-jacents sont supprimés. Si ce paramètre est défini sur `false`, les anciens instantanés sont supprimés des métadonnées de la table, mais leurs fichiers sous-jacents restent dans le stockage en tant que fichiers orphelins.

AWS API

[CreateTableOptimizer](#) Opération d'appel pour activer l'optimiseur de rétention des instantanés pour une table.

Après avoir activé le compactage, l'onglet Optimisation des tables affiche les détails de compactage suivants (après environ 15 à 20 minutes) :

L'heure de début

Heure à laquelle l'optimiseur de rétention des instantanés a démarré. La valeur est un horodatage selon le fuseau UTC.

Durée de l'exécution

Le temps indique le temps nécessaire à l'optimiseur pour terminer la tâche. La valeur est un horodatage selon le fuseau UTC.

Statut

État de l'exécution de l'optimiseur. Les valeurs sont la réussite ou l'échec.

Fichiers de données supprimés

Nombre total de fichiers supprimés.

Fichiers manifestes supprimés

Nombre total de fichiers manifestes supprimés.

Listes de manifestes supprimées

Nombre total de listes de manifestes supprimées.

Mettre à jour l'optimiseur de rétention des instantanés

Vous pouvez mettre à jour la configuration existante d'un optimiseur de rétention des instantanés pour une table Apache Iceberg particulière à l'aide de la AWS Glue console ou de l'UpdateTableOptimizerAPI. AWS CLI

Console

Pour mettre à jour la configuration de conservation des instantanés

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez Catalogue de données, puis choisissez Tables. Dans la liste des tables, choisissez la table Iceberg dont vous souhaitez mettre à jour la configuration de l'optimiseur de rétention des instantanés.
3. Dans la section inférieure de la page de détails des tables, sélectionnez l'onglet Optimisation des tables, puis choisissez Modifier. Vous pouvez également choisir Modifier sous Optimisation dans le menu Actions situé dans le coin supérieur droit de la page.
4. Sur la page Modifier l'optimisation, apportez les modifications souhaitées.
5. Choisissez Save (Enregistrer).

AWS CLI

Pour mettre à jour un optimiseur de conservation des instantanés à l'aide de AWS CLI, vous pouvez utiliser la commande suivante :

```
aws glue update-table-optimizer \  
  --catalog-id 123456789012 \  
  --database-name iceberg_db \  
  --table-name iceberg_table \  
  --table-optimizer-configuration \  
  '{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role"', "enabled": 'true',  
  "vpcConfiguration":  
  {"glueConnectionName": "glue_connection_name"}, "retentionConfiguration":  
  {"icebergConfiguration":  
  {"snapshotRetentionPeriodInDays": 7, "numberOfSnapshotsToRetain": 3, "cleanExpiredFiles": 'true'}}  
  \  
  --type retention
```

Cette commande met à jour la configuration de rétention pour la table spécifiée dans le catalogue, la base de données et la région donnés. Les principaux paramètres sont les suivants :

- `snapshotRetentionPeriodInDays` : le nombre de jours pendant lesquels les instantanés sont conservés avant leur expiration. La valeur par défaut est 1.

- `numberOfSnapshotsToRetain` — Le nombre minimum de clichés à conserver, même s'ils sont antérieurs à la période de conservation. La valeur par défaut est 5.
- `cleanExpiredFiles` — Un booléen indiquant s'il faut supprimer les fichiers de données expirés après l'expiration des instantanés. La valeur par défaut est `true`.

Lorsque ce paramètre est défini sur `true`, les anciens instantanés sont supprimés des métadonnées de la table et leurs fichiers sous-jacents sont supprimés. » Si ce paramètre est défini sur `false`, les anciens instantanés sont supprimés des métadonnées de la table, mais leurs fichiers sous-jacents restent dans le stockage en tant que fichiers orphelins.

API

Pour mettre à jour un optimiseur de table, vous pouvez utiliser l'`UpdateTableOptimizerAPI`. Cette API vous permet de mettre à jour la configuration d'un optimiseur de table existant pour le compactage, la rétention ou la suppression de fichiers orphelins. Les paramètres de la demande incluent :

- `CatalogID` (obligatoire) : ID du catalogue contenant la table
- `DatabaseName` (facultatif) : nom de la base de données contenant la table
- `TableName` (facultatif) : nom de la table
- `type` (obligatoire) : type d'optimiseur de table (compactage, rétention ou `orphan_file_delete`)
- `RetentionConfiguration` (obligatoire) : configuration mise à jour de l'optimiseur de table, y compris l'ARN du rôle, le statut activé, la configuration de rétention et la configuration de suppression des fichiers orphelins.

Désactivation de l'optimiseur de rétention des instantanés

Vous pouvez désactiver l'optimiseur de rétention des instantanés pour une table Apache Iceberg particulière à l'aide de AWS Glue la console ou. AWS CLI

Console

Pour désactiver la conservation des instantanés

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.

2. Choisissez Catalogue de données, puis choisissez Tables. Dans la liste des tables, choisissez la table Iceberg dont vous souhaitez désactiver l'optimiseur pour la conservation des instantanés.
3. Dans la section inférieure de la page des détails de la table, choisissez Optimisation de la table et Désactiver, conservation des instantanés sous Actions.

Vous pouvez également choisir Désactiver sous Optimisation dans le menu Actions situé dans le coin supérieur droit de la page.

4. Choisissez Désactiver dans le message de confirmation. Vous pouvez réactiver l'optimiseur de rétention des instantanés ultérieurement.

Une fois que vous avez confirmé, l'optimiseur de rétention des instantanés est désactivé et l'état de conservation des instantanés revient à `Not enabled`.

AWS CLI

Dans l'exemple suivant, remplacez l'ID de compte par un ID de AWS compte valide. Remplacez le nom de la base de données et le nom de la table par un nom réel de la table Iceberg et le nom de la base de données. Remplacez le `roleArn` par le nom de AWS ressource (ARN) du rôle IAM et le nom réel du rôle IAM disposant des autorisations requises pour exécuter l'optimiseur de rétention.

```
aws glue update-table-optimizer \  
  --catalog-id 123456789012 \  
  --database-name iceberg_db \  
  --table-name iceberg_table \  
  --table-optimizer-configuration \  
  '{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role", "vpcConfiguration": \  
  {"glueConnectionName":"glue_connection_name"}, "enabled":'false'}\' \  
  --type retention
```

AWS API

[UpdateTableOptimizer](#) Opération d'appel pour désactiver l'optimiseur de rétention des instantanés pour une table spécifique.

Supprimer des fichiers orphelins

AWS Glue Data Catalog vous permet de supprimer les fichiers orphelins de vos tables Iceberg. Les fichiers orphelins sont des fichiers qui existent dans votre source de données Amazon S3 à l'emplacement de table spécifié, qui ne sont pas suivis par les métadonnées de la table Iceberg et qui sont plus anciens que la limite d'âge que vous avez configurée. Ces fichiers orphelins peuvent s'accumuler au fil du temps en raison d'opérations telles que le compactage, la suppression de partitions ou la réécriture de tables, et occuper un espace de stockage inutile.

L'optimiseur de suppression des fichiers orphelins AWS Glue analyse les métadonnées de la table et les fichiers de données réels, identifie les fichiers orphelins et les supprime pour récupérer de l'espace de stockage.

Vous pouvez initier la suppression du fichier orphelin en créant un optimiseur de table de suppression de fichiers orphelins dans le catalogue de données.

Important

Par défaut, la suppression des fichiers orphelins évalue les fichiers situés à l'emplacement de votre AWS Glue table. Bien que vous puissiez configurer un sous-préfixe pour limiter la portée de l'évaluation, vous devez vous assurer que l'emplacement de votre table ne contient pas de fichiers provenant d'autres sources de données ou tables. Si l'emplacement de votre table chevauche celui d'autres sources de données, le service peut identifier et supprimer des fichiers non liés en tant qu'orphelins.

Rubriques

- [Activation de la suppression des fichiers orphelins](#)
- [Mise à jour de l'optimiseur de suppression de fichiers orphelins](#)
- [Désactiver la suppression des fichiers orphelins](#)

Activation de la suppression des fichiers orphelins

Vous pouvez utiliser AWS Glue la console ou l' AWS API pour activer la suppression des fichiers orphelins pour vos tables Apache Iceberg dans le catalogue de données. AWS CLI Pour les nouvelles tables, vous pouvez choisir Apache Iceberg comme format de table et activer l'optimiseur de suppression des fichiers orphelins lorsque vous créez la table. La conservation des instantanés est désactivée par défaut pour les nouvelles tables.

Console

Pour activer la suppression des fichiers orphelins

1. Ouvrez la AWS Glue console <https://console.aws.amazon.com/glue/> et connectez-vous en tant qu'administrateur du lac de données, créateur de table ou utilisateur ayant obtenu les `lakeformation:GetDataAccess` autorisations `glue:UpdateTable` et sur la table.
2. Dans le panneau de navigation, sous Catalogue de données, choisissez Tables.
3. Sur la page Tables, choisissez une table Iceberg dans laquelle vous souhaitez activer la suppression des fichiers orphelins.

Choisissez l'onglet Optimisation des tables dans la partie inférieure de la page, puis sélectionnez Activer, suppression des fichiers orphelins dans Actions.

Vous pouvez également sélectionner Activer sous Optimisation dans le menu Actions situé dans le coin supérieur droit de la page.

4. Sur la page Activer l'optimisation, sélectionnez Suppression des fichiers orphelins sous Options d'optimisation.
5. Si vous choisissez d'utiliser les paramètres par défaut, tous les fichiers orphelins seront supprimés au bout de 3 jours. Si vous souhaitez conserver les fichiers orphelins pendant un certain nombre de jours, choisissez Personnaliser les paramètres.
6. Choisissez ensuite un rôle IAM doté des autorisations requises pour supprimer les fichiers orphelins.
7. Si vous avez des configurations de politique de sécurité dans lesquelles l'optimiseur de table Iceberg doit accéder aux compartiments Amazon S3 à partir d'un Virtual Private Cloud (VPC) spécifique, créez AWS Glue une connexion réseau ou utilisez une connexion réseau existante.

Si aucune connexion AWS Glue VPC n'est déjà configurée, créez-en une nouvelle en suivant les étapes de la section [Création de connexions pour les connecteurs](#) à l'aide de la AWS Glue console ou du /SDK. AWS CLI

8. Si vous choisissez Personnaliser les paramètres, entrez le nombre de jours pendant lesquels les fichiers doivent être conservés avant leur suppression dans Configuration de la suppression des fichiers orphelins.
9. Choisissez Activer l'optimisation.

AWS CLI

Pour activer la suppression des fichiers orphelins pour une table Iceberg dans AWS Glue, vous devez créer un optimiseur de table de type `orphan_file_deletion` et définir le `enabled` champ sur `true`. Pour créer un optimiseur de suppression de fichiers orphelins pour une table Iceberg à l'aide de AWS CLI, vous pouvez utiliser la commande suivante :

```
aws glue create-table-optimizer \  
  --catalog-id 123456789012 \  
  --database-name iceberg_db \  
  --table-name iceberg_table \  
  --table-optimizer-configuration \  
  '{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role","enabled":true, \  
  "vpcConfiguration":{ \  
  "glueConnectionName":"glue_connection_name"}, "orphanFileDeletionConfiguration": \  
  {"icebergConfiguration":{"orphanFileRetentionPeriodInDays":3, "location":'S3 \  
  location'}}}' \  
  --type orphan_file_deletion
```

Cette commande crée un optimiseur de suppression de fichiers orphelins pour la table Iceberg spécifiée. Les principaux paramètres sont les suivants :

- `roleArn` : l'ARN du rôle IAM autorisé à accéder au compartiment S3 et aux ressources Glue.
- `activé` — Définissez ce paramètre sur `true` pour activer l'optimiseur.
- `orphanFileRetentionPeriodInDays` — Le nombre de jours pendant lesquels les fichiers orphelins sont conservés avant de les supprimer (minimum 1 jour).
- `type` — Définissez la valeur `orphan_file_delete` pour créer un optimiseur de suppression de fichiers orphelins.

Après avoir créé l'optimiseur de table, il supprimera régulièrement les fichiers orphelins (une fois par jour s'il est laissé activé). Vous pouvez vérifier les exécutions à l'aide de l'`list-table-optimizer-runs` API. La tâche de suppression des fichiers orphelins identifiera et supprimera les fichiers qui ne sont pas suivis dans les métadonnées Iceberg de la table.

API

[CreateTableOptimizer](#) Opération d'appel pour créer l'optimiseur de suppression de fichiers orphelins pour une table spécifique.

Mise à jour de l'optimiseur de suppression de fichiers orphelins

Vous pouvez modifier la configuration de l'optimiseur de suppression de fichiers orphelins, par exemple en modifiant la période de conservation des fichiers orphelins ou le rôle IAM utilisé par l'optimiseur à l'aide de la AWS Glue console ou de l'opération `AWS CLI UpdateTableOptimizer`.

AWS Management Console

Pour mettre à jour l'optimiseur de suppression de fichiers orphelins

1. Choisissez Catalogue de données, puis choisissez Tables. Dans la liste des tables, choisissez la table dans laquelle vous souhaitez mettre à jour la configuration de l'optimiseur de suppression de fichiers orphelins.
2. Dans la section inférieure de la page de détails des tables, choisissez Optimisation des tables, puis sélectionnez Modifier.
3. Sur la page Modifier l'optimisation, apportez les modifications souhaitées.
4. Choisissez Save (Enregistrer).

AWS CLI

Vous pouvez utiliser l'`update-table-optimizer` pour mettre à jour l'optimiseur de suppression de fichiers orphelins dans AWS Glue, vous pouvez utiliser l'appel. Cela vous permet de modifier le `icebergConfiguration` champ `OrphanFileDeletionConfiguration` dans lequel vous pouvez spécifier la mise `OrphanFileRetentionPeriodInDays` à jour pour définir le nombre de jours pendant lesquels les fichiers orphelins seront conservés, pour spécifier l'emplacement de la table Iceberg dans laquelle les fichiers orphelins seront supprimés.

```
aws glue update-table-optimizer \
  --catalog-id 123456789012 \
  --database-name iceberg_db \
  --table-name Iceberg_table \
  --table-optimizer-configuration
  '{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role","enabled":true,
  "vpcConfiguration":
  {"glueConnectionName":"glue_connection_name"},"orphanFileDeletionConfiguration":
  {"icebergConfiguration":{"orphanFileRetentionPeriodInDays":5}}}' \
  --type orphan_file_deletion
```


API

Appelez l'[UpdateTableOptimizer](#) opération pour mettre à jour l'optimiseur de suppression de fichiers orphelins pour une table.

Désactiver la suppression des fichiers orphelins

Vous pouvez désactiver l'optimiseur de suppression de fichiers orphelins pour une table Apache Iceberg particulière à l'aide AWS Glue de la console ou. AWS CLI

Console

Pour désactiver la suppression des fichiers orphelins

1. Choisissez Catalogue de données, puis choisissez Tables. Dans la liste des tables, choisissez la table Iceberg dont vous souhaitez désactiver l'optimiseur pour la suppression des fichiers orphelins.
2. Dans la section inférieure de la page des détails du tableau, choisissez l'onglet Optimisation du tableau.
3. Choisissez Actions, puis sélectionnez Désactiver, Suppression des fichiers orphelins.

Vous pouvez également choisir Désactiver sous Optimisation dans le menu Actions.

4. Choisissez Désactiver dans le message de confirmation. Vous pouvez réactiver l'optimiseur de suppression des fichiers orphelins ultérieurement.

Une fois que vous avez confirmé, l'optimiseur de suppression des fichiers orphelins est désactivé et le statut de suppression des fichiers orphelins revient à. Not enabled

AWS CLI

Dans l'exemple suivant, remplacez l'ID de compte par un ID de AWS compte valide. Remplacez le nom de la base de données et le nom de la table par un nom réel de la table Iceberg et le nom de la base de données. Remplacez le `roleArn` par le nom de AWS ressource (ARN) du rôle IAM et le nom réel du rôle IAM disposant des autorisations requises pour désactiver l'optimiseur.

```
aws glue update-table-optimizer \  
  --catalog-id 123456789012 \  
  --database-name iceberg_db \  
  --table-name iceberg_db \  
  --role-arn arn:aws:iam::123456789012:role/glue-optimizer-role
```

```
--table-name iceberg_table \  
--table-optimizer-configuration  
'{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role", "enabled":'false'}'\  
--type orphan_file_deletion
```

API

Appelez l'[UpdateTableOptimizer](#) opération pour désactiver l'optimiseur de rétention des instantanés pour une table spécifique.

Afficher les détails de l'optimisation

Vous pouvez consulter l'état d'optimisation des tables Apache Iceberg dans la AWS Glue console ou à l'aide des opérations d' AWS API. AWS CLI

Console

Pour afficher l'état d'optimisation des tables Iceberg (console)

- Vous pouvez consulter l'état d'optimisation des tables Iceberg sur la AWS Glue console en choisissant une table Iceberg dans la liste des tables sous Catalogue de données. Sous Optimisation des tables. Choisissez l'option Afficher tout

Schema

Table optimization

Column statistics - new

► Optimization configuration

Configure Apache Iceberg table optimizations to optimize storage and improve query performance.

Actions ▼Edit

Compaction history (5686)

Small Amazon S3 objects are automatically compacted into larger objects. View the status of the data compaction run. [Learn more](#)

View metrics on CloudWatch

Start time	Status	End time	Files compacted	Bytes compacted	DPU's consumed
Friday, August 23, 2024 at 10:03 PM UTC	Success	Friday, August 23, 2024 at 10:04 PM UTC	168	4.23 Mb	2
Friday, August 23, 2024 at 9:53 PM UTC	Success	Friday, August 23, 2024 at 9:54 PM UTC	150	4.49 Mb	2
Friday, August 23, 2024 at 9:44 PM UTC	Success	Friday, August 23, 2024 at 9:45 PM UTC	150	4.44 Mb	2

View all

Snapshot retention history (24)

Expired snapshots and files are automatically deleted.

View metrics on CloudWatch

Start time	Status	End time	Data files deleted	Manifest files deleted	Manifest lists deleted	DPU's consumed
Friday, August 23, 2024 at 7:53 PM UTC	Success	Friday, August 23, 2024 at 8:08 PM UTC	25311	3022	1144	2
Thursday, August 22, 2024 at 7:53 PM UTC	Success	Thursday, August 22, 2024 at 8:09 PM UTC	25009	2983	1129	2
Wednesday, August 21, 2024 at 8:08 PM UTC	Success	Wednesday, August 21, 2024 at 8:24 PM UTC	25814	2884	1146	2

View all

Orphan file deletion history (21)

Orphan files are automatically deleted.

View metrics on CloudWatch

Start time	Status	End time	Orphan files deleted	DPU's consumed
Friday, August 23, 2024 at 12:23 AM UTC	Success	Friday, August 23, 2024 at 12:31 AM UTC	1133	2
Thursday, August 22, 2024 at 12:23 AM UTC	Success	Thursday, August 22, 2024 at 12:31 AM UTC	1148	2
Wednesday, August 21, 2024 at 12:23 AM UTC	Success	Wednesday, August 21, 2024 at 12:31 AM UTC	1148	2

View all

AWS CLI

Vous pouvez consulter les détails de l'optimisation à l'aide de AWS CLI.

Dans les exemples suivants, remplacez l'ID de compte par un ID de AWS compte valide, le nom de la base de données et le nom de la table par le nom réel de la table Iceberg. Pour type, fournissez et type d'optimisation. Les valeurs acceptables sont `compaction`, `retention` et `orphan-file-deletion`.

- Pour obtenir les détails de la dernière exécution du compactage d'une table

```
aws get-table-optimizer \  
  --catalog-id 123456789012 \  
  --database-name iceberg_db \  
  --table-name iceberg_table \  
  --type compaction
```

- Utilisez l'exemple suivant pour récupérer l'historique d'un optimiseur pour une table spécifique.

```
aws list-table-optimizer-runs \  
  --catalog-id 123456789012 \  
  --database-name iceberg_db \  
  --table-name iceberg_table \  
  --type compaction
```

- L'exemple suivant montre comment récupérer le cycle d'optimisation et les détails de configuration de plusieurs optimiseurs. Vous pouvez spécifier un maximum de 20 optimiseurs.

```
aws glue batch-get-table-optimizer \  
  --entries '[{"catalogId":"123456789012", "databaseName":"iceberg_db",  
  "tableName":"iceberg_table", "type":"compaction"}]'
```

API

- Utilisez l'opération `GetTableOptimizer` pour récupérer les détails de la dernière exécution d'un optimiseur.
- Utilisez l'opération `ListTableOptimizerRuns` pour récupérer l'historique d'un optimiseur donné sur une table spécifique. Vous pouvez spécifier 20 optimiseurs en un seul appel d'API.
- Utilisez cette [BatchGetTableOptimizer](#) opération pour récupérer les détails de configuration de plusieurs optimiseurs de votre compte.

Afficher Amazon CloudWatch les métriques

Une fois les optimiseurs de table exécutés avec succès, le service crée des Amazon CloudWatch mesures sur les performances de la tâche d'optimisation. Vous pouvez accéder aux CloudWatch métriques et choisir Metrics, All metrics. Vous pouvez filtrer les métriques en fonction de l'espace de noms spécifique (par exemple AWS Glue), du nom de la table ou du nom de la base de données.

Pour de plus amples informations, consultez [Affichage des métriques disponibles](#) dans le Guide de l'utilisateur Amazon CloudWatch .

Compactage

- Nombre d'octets compactés
- Nombre de fichiers compactés
- Nombre de DPU alloués à la tâche
- Durée de la tâche (heures)

Conservation des instantanés

- Nombre de fichiers de données supprimés
- Nombre de fichiers manifestes supprimés
- Nombre de listes de manifestes supprimées
- Durée de la tâche (heures)

Suppression de fichiers orphelins

- Nombre de fichiers orphelins supprimés
- Durée de la tâche (heures)

Suppression d'un optimiseur

Vous pouvez supprimer un optimiseur et les métadonnées associées à la table à l'aide d' AWS CLI une opération d' AWS API.

Exécutez la AWS CLI commande suivante pour supprimer l'historique d'optimisation d'une table. Vous devez spécifier l'optimiseur type ainsi que l'ID du catalogue, le nom de la base de données

et le nom de la table. Les valeurs acceptables sont les suivantes : `compactionretention`, `etorphan_file_deletion`.

```
aws glue delete-table-optimizer \  
  --catalog-id 123456789012 \  
  --database-name iceberg_db \  
  --table-name iceberg_table \  
  --type compaction
```

Utilisez l'opération `DeleteTableOptimizer` pour supprimer un optimiseur pour une table.

Considérations et restrictions

Cette section inclut les éléments à prendre en compte lors de l'utilisation d'optimiseurs de table dans le AWS Glue Data Catalog.

Formats pris en charge et limites pour le compactage géré des données

Le compactage des données prend en charge une variété de types de données et de formats de compression pour la lecture et l'écriture de données, y compris la lecture de données à partir de tables chiffrées.

Le compactage des données prend en charge :

- Chiffrement : le compactage des données prend uniquement en charge le chiffrement par défaut d'Amazon S3 (SSE-S3) et le chiffrement KMS côté serveur (SSE-KMS).
- Stratégies de compactage : binpack, tri et tri par ordre Z
- Vous pouvez exécuter le compactage depuis le compte où réside le catalogue de données lorsque le compartiment Amazon S3 qui stocke les données sous-jacentes se trouve dans un autre compte. Pour ce faire, le rôle de compactage nécessite l'accès au compartiment Amazon S3.

Le compactage des données ne prend pas en charge actuellement :

- Compactage sur des tables multicomptes : vous ne pouvez pas exécuter de compactage sur des tables multicomptes.
- Compactage sur des tables entre régions : vous ne pouvez pas exécuter de compactage sur des tables entre régions.
- Activation du compactage sur des liens de ressources

- Tables de la classe de stockage Amazon S3 Express One Zone : vous ne pouvez pas exécuter le compactage sur les tables S3 Express One Zone Iceberg.
- La stratégie de compactage par ordre Z ne prend pas en charge les types de données suivants :
 - Décimal
 - TimestampWithoutZone

Considérations relatives à la conservation des instantanés et aux optimiseurs de suppression de fichiers orphelins

Les considérations suivantes s'appliquent à la conservation des instantanés et aux optimiseurs de suppression de fichiers orphelins.

- Les processus de conservation des instantanés et de suppression de fichiers orphelins ont une limite maximale de suppression de 1 000 000 de fichiers par exécution. Lorsque vous supprimez des instantanés expirés, si le nombre de fichiers éligibles à la suppression dépasse 1 000 000, tous les fichiers restants au-delà de ce seuil continueront d'exister dans le stockage de la table en tant que fichiers orphelins.
- Les instantanés ne seront conservés par l'optimiseur de rétention des instantanés que lorsque les deux critères sont satisfaits : le nombre minimum de clichés à conserver et la période de conservation spécifiée.
- L'optimiseur de rétention des instantanés supprime les métadonnées des instantanés expirés d'Apache Iceberg, empêchant ainsi les requêtes de voyager dans le temps pour les instantanés expirés et supprimant éventuellement les fichiers de données associés.
- L'optimiseur de suppression de fichiers orphelins supprime les données orphelins et les fichiers de métadonnées qui ne sont plus référencés par les métadonnées Iceberg si leur date de création est antérieure à la période de rétention des fichiers orphelins à compter de l'exécution de l'optimiseur.
- Apache Iceberg facilite le contrôle des versions par le biais de branches et de balises, appelées pointeurs vers des états de snapshots spécifiques. Chaque branche et étiquette suit son propre cycle de vie indépendant, régi par des politiques de rétention définies à leurs niveaux respectifs. Les AWS Glue Data Catalog optimiseurs tiennent compte de ces politiques de cycle de vie, garantissant ainsi le respect des règles de conservation spécifiées. Les politiques de rétention au niveau des succursales et des balises ont priorité sur les configurations de l'optimiseur.

Pour plus d'informations, consultez [Branching and Tagging](#) dans la documentation d'Apache Iceberg.

- Les optimiseurs de conservation des instantanés et de suppression de fichiers orphelins supprimeront les fichiers éligibles au nettoyage conformément aux paramètres configurés. Améliorez votre contrôle sur la suppression de fichiers en mettant en œuvre des politiques de gestion des versions et de cycle de vie S3 sur les compartiments appropriés.

Pour obtenir des instructions détaillées sur la configuration de la gestion des versions et la création de règles de cycle de vie, consultez <https://docs.aws.amazon.com/AmazonS3/latest/userguide/Versioning.html>.

- Pour déterminer correctement les fichiers orphelins, assurez-vous que l'emplacement de la table fourni et les éventuels sous-chemins ne se chevauchent pas ou ne contiennent pas de données provenant d'autres tables ou sources de données. Si les chemins se chevauchent, vous risquez une perte de données irrécupérable en cas de suppression involontaire de fichiers.

Régions prises en charge pour les optimiseurs de tables

Les fonctionnalités d'optimisation des tables (compactage, conservation des instantanés et suppression de fichiers orphelins) pour AWS Glue Data Catalog sont disponibles dans les versions suivantes : Régions AWS

- Asie-Pacifique (Tokyo)
- Asie-Pacifique (Séoul)
- Asie-Pacifique (Mumbai)
- Asie-Pacifique (Singapour)
- Asie-Pacifique (Sydney)
- Asie-Pacifique (Jakarta)
- Canada (Centre)
- Europe (Irlande)
- Europe (Londres)
- Europe (Francfort)
- Europe (Stockholm)
- USA Est (Virginie du Nord)
- USA Est (Ohio)
- USA Ouest (Oregon)
- Amérique du Sud (São Paulo)

Optimisation des performances des requêtes pour les tables Iceberg

Apache Iceberg est un format de table ouverte très performant pour de grands ensembles de données analytiques. AWS Glue prend en charge le calcul et la mise à jour du nombre de valeurs distinctes (NDVs) pour chaque colonne des tables Iceberg. Ces statistiques peuvent améliorer l'optimisation des requêtes, la gestion des données et l'efficacité des performances pour les ingénieurs de données et les scientifiques travaillant avec des ensembles de données à grande échelle.

AWS Glue estime le nombre de valeurs distinctes dans chaque colonne de la table Iceberg et les stocke dans des fichiers [Puffin](#) sur Amazon S3 associés à des instantanés de table Iceberg. Puffin est un format de fichier Iceberg conçu pour stocker des métadonnées telles que des index, des statistiques et des croquis. Le stockage de croquis dans des fichiers Puffin liés à des instantanés garantit la cohérence transactionnelle et la fraîcheur des statistiques NDV.

Vous pouvez configurer pour exécuter la tâche de génération de statistiques de colonne à l'aide de AWS Glue la console ou AWS CLI. Lorsque vous lancez le processus, AWS Glue démarre une tâche Spark en arrière-plan et met à jour les métadonnées de la AWS Glue table dans le catalogue de données. Vous pouvez consulter les statistiques des colonnes à l'aide de la AWS Glue console AWS CLI ou en appelant l'opération [GetColumnStatisticsForTableAPI](#).

Note

Si vous utilisez AWS Lake Formation des autorisations pour contrôler l'accès à la table, le rôle assumé par la tâche de statistiques sur les colonnes nécessite un accès complet à la table pour générer des statistiques.

Rubriques

- [Conditions préalables à la génération de statistiques de colonne](#)
- [Génération de statistiques de colonnes pour les tables Iceberg](#)
- [Consultez aussi](#)

Conditions préalables à la génération de statistiques de colonne

Pour générer ou mettre à jour des statistiques de colonne pour les tables Iceberg, la tâche de génération de statistiques assume un rôle AWS Identity and Access Management (IAM) en votre

nom. Sur la base des autorisations accordées au rôle, la tâche de génération de statistiques de colonne peut lire les données à partir du magasin de données Amazon S3.

Lorsque vous configurez la tâche de génération de statistiques de AWS Glue colonne, vous pouvez créer un rôle qui inclut la politique `AWSGlueServiceRole` AWS gérée ainsi que la politique en ligne requise pour la source de données spécifiée.

Si vous spécifiez un rôle existant pour générer des statistiques de colonne, assurez-vous qu'il inclut la `AWSGlueServiceRole` politique ou un équivalent (ou une version réduite de cette politique), ainsi que les politiques intégrées requises.

Pour plus d'informations sur les autorisations requises, consultez [Conditions préalables à la génération de statistiques de colonne](#).

Génération de statistiques de colonnes pour les tables Iceberg

Procédez comme suit pour configurer un calendrier de génération de statistiques dans le catalogue de données à l'aide de la AWS Glue console AWS CLI ou de l'opération ou exécutez `StartColumnStatisticsTaskRun`opération.

Pour générer des statistiques sur les colonnes

1. Connectez-vous à la AWS Glue console à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez Tables sous Catalogue de données.
3. Choisissez une table Iceberg dans la liste.
4. Choisissez Statistiques de colonne, Générer à la demande, dans le menu Actions.

Vous pouvez également choisir le bouton Générer des statistiques sous l'onglet Statistiques de colonne dans la section inférieure de la page Tables.

5. Sur la page Générer des statistiques, fournissez les détails relatifs à la génération des statistiques. Suivez les étapes 6 à 11 de la [Génération de statistiques sur les colonnes selon un calendrier](#) section pour configurer un calendrier de génération de statistiques pour les tables Iceberg.

Vous pouvez également choisir de générer des statistiques de colonnes à la demande en suivant les instructions du [Génération de statistiques de colonnes à la demande](#)

 Note

L'option d'échantillonnage n'est pas disponible pour les tables Iceberg.

AWS Glue calcule le nombre de valeurs distinctes pour chaque colonne de la table Iceberg dans un nouveau fichier Puffin validé avec l'ID de snapshot spécifié dans votre emplacement Amazon S3.

Consultez aussi

- [Affichage des statistiques de colonne](#)
- [Affichage des exécutions de tâches de statistiques de colonne](#)
- [Arrêt d'exécution de la tâche de statistiques de colonne](#)
- [Supprimer les statistiques de colonne](#)

Gestion du catalogue de données

AWS Glue Data Catalog Il s'agit d'un référentiel de métadonnées central qui stocke les métadonnées structurelles et opérationnelles de vos ensembles de données Amazon S3. La gestion efficace du catalogue de données est essentielle au maintien de la qualité, des performances, de la sécurité et de la gouvernance des données.

En comprenant et en appliquant ces pratiques de gestion du catalogue de données, vous pouvez vous assurer que vos métadonnées restent précises, performantes, sécurisées et bien gouvernées au fur et à mesure de l'évolution de votre environnement de données.

Cette section couvre les aspects suivants de la gestion du catalogue de données :

- Mise à jour du schéma de table et des partitions Au fur et à mesure de l'évolution de vos données, vous devrez peut-être mettre à jour le schéma de table ou la structure de partition définis dans le catalogue de données. Pour plus d'informations sur la façon d'effectuer ces mises à jour par programmation à l'aide de l' AWS Glue ETL, consultez. [Mise à jour du schéma et ajout de nouvelles partitions dans le catalogue de données à l'aide de AWS Glue tâches ETL](#)
- Gestion des statistiques sur les colonnes : des statistiques précises sur les colonnes permettent d'optimiser les plans de requêtes et d'améliorer les performances. Pour plus d'informations sur la

façon de générer, de mettre à jour et de gérer les statistiques des colonnes, consultez [Optimisation des performances des requêtes à l'aide des statistiques des colonnes](#).

- **Chiffrement du catalogue de données** Pour protéger les métadonnées sensibles, vous pouvez chiffrer votre catalogue de données à l'aide de AWS Key Management Service (AWS KMS). Cette section explique comment activer et gérer le chiffrement de votre catalogue de données.
- **La sécurisation du catalogue de données avec AWS Lake Formation** Lake Formation fournit une approche globale de la sécurité des lacs de données et du contrôle d'accès. Vous pouvez utiliser Lake Formation pour sécuriser et régir l'accès à votre catalogue de données et aux données sous-jacentes.

Rubriques

- [Mise à jour du schéma et ajout de nouvelles partitions dans le catalogue de données à l'aide de AWS Glue tâches ETL](#)
- [Optimisation des performances des requêtes à l'aide des statistiques des colonnes](#)
- [Chiffrement de votre catalogue de données](#)
- [Sécurisation de votre catalogue de données à l'aide de Lake Formation](#)
- [Utilisation des AWS Glue Data Catalog vues dans AWS Glue](#)

Mise à jour du schéma et ajout de nouvelles partitions dans le catalogue de données à l'aide de AWS Glue tâches ETL

Votre travail d'extraction, de transformation et de chargement (ETL) peut créer de nouvelles partitions de table dans le magasin de données cible. Le schéma de votre jeu de données peut évoluer et diverger par rapport au AWS Glue Schéma du catalogue de données au fil du temps. AWS Glue Les tâches ETL fournissent désormais plusieurs fonctions que vous pouvez utiliser dans votre script ETL pour mettre à jour votre schéma et vos partitions dans le catalogue de données. Ces fonctions vous permettent de voir les résultats de votre tâche ETL dans le catalogue de données, sans avoir à exécuter à nouveau l'crawler.

Nouvelles partitions

Si vous souhaitez afficher les nouvelles partitions dans le AWS Glue Data Catalog, vous pouvez effectuer l'une des opérations suivantes :

- Une fois la tâche terminée, réexécutez l'crawler pour afficher les nouvelles partitions sur la console.

- Une fois la tâche terminée, affichez immédiatement les nouvelles partitions sur la console, sans avoir à réexécuter l'crawler. Pour activer cette fonctionnalité, ajoutez quelques lignes de code au script ETL, comme illustré dans les exemples suivants. Le code utilise l'argument `enableUpdateCatalog` pour indiquer que le catalogue de données doit être mis à jour pendant l'exécution de la tâche lors de la création des partitions.

Méthode 1 :

Transmettez `enableUpdateCatalog` et `partitionKeys` dans un argument d'options.

Python

```
additionalOptions = {"enableUpdateCatalog": True}
additionalOptions["partitionKeys"] = ["region", "year", "month", "day"]

sink = glueContext.write_dynamic_frame_from_catalog(frame=last_transform,
    database=<target_db_name>,

    table_name=<target_table_name>, transformation_ctx="write_sink",

    additional_options=additionalOptions)
```

Scala

```
val options = JsonOptions(Map(
    "path" -> <S3_output_path>,
    "partitionKeys" -> Seq("region", "year", "month", "day"),
    "enableUpdateCatalog" -> true))
val sink = glueContext.getCatalogSink(
    database = <target_db_name>,
    tableName = <target_table_name>,
    additionalOptions = options)sink.writeDynamicFrame(df)
```

Méthode 2 :

Transmettez `enableUpdateCatalog` et `partitionKeys` dans `getSink()` et appelez `setCatalogInfo()` au niveau de l'objet `DataSink`.

Python

```
sink = glueContext.getSink(
```

```
connection_type="s3",
path="<S3_output_path>",
enableUpdateCatalog=True,
partitionKeys=["region", "year", "month", "day"])
sink.setFormat("json")
sink.setCatalogInfo(catalogDatabase=<target_db_name>,
catalogTableName=<target_table_name>)
sink.writeFrame(last_transform)
```

Scala

```
val options = JsonOptions(
  Map("path" -> <S3_output_path>,
    "partitionKeys" -> Seq("region", "year", "month", "day"),
    "enableUpdateCatalog" -> true))
val sink = glueContext.getSink("s3", options).withFormat("json")
sink.setCatalogInfo(<target_db_name>, <target_table_name>)
sink.writeDynamicFrame(df)
```

Vous pouvez désormais créer de nouvelles tables de catalogue, mettre à jour des tables existantes avec un schéma modifié et ajouter de nouvelles partitions de table dans le catalogue de données à l'aide d'un AWS Glue Job ETL lui-même, sans qu'il soit nécessaire de réexécuter les robots d'exploration.

Mise à jour du schéma de table

Si vous souhaitez remplacer le schéma de la table du catalogue de données, vous pouvez effectuer l'une des opérations suivantes :

- Une fois la tâche terminée, exécutez à nouveau l'crawler et assurez-vous que celui-ci est configuré pour mettre à jour également la définition de la table. Affichez les nouvelles partitions sur la console ainsi que les mises à jour de schéma lorsque l'crawler se termine. Pour plus d'informations, consultez [Configuration d'un crawler utilisant l'API](#).
- Une fois la tâche terminée, affichez immédiatement le schéma modifié sur la console, sans avoir à exécuter de nouveau l'crawler. Pour activer cette fonctionnalité, ajoutez quelques lignes de code au script ETL, comme illustré dans les exemples suivants. Le code utilise `enableUpdateCatalog` défini sur `true` et `updateBehavior` défini sur `UPDATE_IN_DATABASE`, ce qui indique que le schéma doit être remplacé et que de nouvelles partitions doivent être ajoutées au catalogue de données pendant l'exécution de la tâche.

Python

```
additionalOptions = {
    "enableUpdateCatalog": True,
    "updateBehavior": "UPDATE_IN_DATABASE"}
additionalOptions["partitionKeys"] = ["partition_key0", "partition_key1"]

sink = glueContext.write_dynamic_frame_from_catalog(frame=last_transform,
    database=<dst_db_name>,
    table_name=<dst_tbl_name>, transformation_ctx="write_sink",
    additional_options=additionalOptions)
job.commit()
```

Scala

```
val options = JsonOptions(Map(
    "path" -> outputPath,
    "partitionKeys" -> Seq("partition_0", "partition_1"),
    "enableUpdateCatalog" -> true))
val sink = glueContext.getCatalogSink(database = nameSpace, tableName = tableName,
    additionalOptions = options)
sink.writeDynamicFrame(df)
```

Vous pouvez également définir la valeur de `updateBehavior` sur `LOG` si vous souhaitez empêcher le remplacement du schéma de table, mais que vous souhaitez toujours ajouter les nouvelles partitions. Comme la valeur par défaut de `updateBehavior` est `UPDATE_IN_DATABASE`, si vous ne le définissez pas explicitement, le schéma de table est remplacé.

Si `enableUpdateCatalog` n'a pas la valeur `true`, quelle que soit l'option sélectionnée pour `updateBehavior`, la tâche ETL ne mettra pas à jour la table dans le catalogue de données.

Création de tables

Vous pouvez également utiliser les mêmes options pour créer une table dans le catalogue de données. Vous pouvez spécifier la base de données et le nouveau nom de table avec `setCatalogInfo`.

Python

```
sink = glueContext.getSink(connection_type="s3", path="s3://path/to/data",
```

```
enableUpdateCatalog=True, updateBehavior="UPDATE_IN_DATABASE",
partitionKeys=["partition_key0", "partition_key1"])
sink.setFormat("<format>")
sink.setCatalogInfo(catalogDatabase=<dst_db_name>, catalogTableName=<dst_tbl_name>)
sink.writeFrame(last_transform)
```

Scala

```
val options = JsonOptions(Map(
  "path" -> outputPath,
  "partitionKeys" -> Seq("<partition_1>", "<partition_2>"),
  "enableUpdateCatalog" -> true,
  "updateBehavior" -> "UPDATE_IN_DATABASE"))
val sink = glueContext.getSink(connectionType = "s3", connectionOptions =
  options).withFormat("<format>")
sink.setCatalogInfo(catalogDatabase = "<dst_db_name>", catalogTableName =
  "<dst_tbl_name>")
sink.writeDynamicFrame(df)
```

Restrictions

Prenez note des restrictions suivantes :

- Seules des cibles Amazon Simple Storage Service (Amazon S3) sont prises en charge.
- La fonctionnalité `enableUpdateCatalog` n'est pas prise en charge pour les tables gouvernées.
- Seuls les formats suivants sont pris en charge : json, csv, avro et parquet.
- Pour créer ou mettre à jour des tables avec la parquet classification, vous devez utiliser AWS Glue graveur de parquet optimisé pour DynamicFrames. Cela peut être réalisé à l'aide d'un des moyens suivants :
 - Si vous mettez à jour une table existante dans le catalogue avec la classification parquet, la propriété de la table `"useGlueParquetWriter"` doit être définie sur `true` avant que vous ne la mettiez à jour. Vous pouvez définir cette propriété via le AWS Glue APIs /SDK, via la console ou via une instruction Athena DDL.

Une fois la propriété de la table de catalogue définie, vous pouvez utiliser l'extrait de code suivant pour mettre à jour la table de catalogue avec les nouvelles données :

```
glueContext.write_dynamic_frame.from_catalog(
    frame=frameToWrite,
    database="dbName",
    table_name="tableName",
    additional_options={
        "enableUpdateCatalog": True,
        "updateBehavior": "UPDATE_IN_DATABASE"
    }
)
```

- Si la table n'existe pas déjà dans le catalogue, vous pouvez utiliser la méthode `getSink()` de votre script avec `connection_type="s3"` pour ajouter la table et ses partitions au catalogue, ainsi que pour écrire les données sur Amazon S3. Fournissez les `partitionKeys` et la compression appropriés pour votre flux de travail.


```
s3sink = glueContext.getSink(  
    path="s3://bucket/folder/",  
    connection_type="s3",  
    updateBehavior="UPDATE_IN_DATABASE",  
    partitionKeys=[],  
    compression="snappy",  
    enableUpdateCatalog=True  
)  
  
s3sink.setCatalogInfo(  
    catalogDatabase="dbName", catalogTableName="tableName"  
)  
  
s3sink.setFormat("parquet", useGlueParquetWriter=True)  
s3sink.writeFrame(frameToWrite)
```

- La valeur de `glueparquet format` est une ancienne méthode permettant d'activer le rédacteur de AWS Glue parquet.
- Quand `updateBehavior` a la valeur `LOG`, de nouvelles partitions sont ajoutées uniquement si le schéma `DynamicFrame` est équivalent ou qu'il contient un sous-ensemble des colonnes définies dans le schéma de la table du catalogue de données.
- Les mises à jour du schéma ne sont pas prises en charge pour les tables non partitionnées (qui n'utilisent pas l'option « `partitionKeys` »).
- Vos clés de partition (`partitionKeys`) doivent être équivalentes, et dans le même ordre, entre votre paramètre passé dans votre script ETL et les clés de partition (`partitionKeys`) du schéma de votre table du catalogue de données.
- Cette fonction ne prend pas encore en charge la mise à jour/création de tables dans lesquelles les schémas de mise à jour sont imbriqués (par exemple, les tableaux à l'intérieur de structures).

Pour de plus amples informations, veuillez consulter [the section called “AWS Glue pour Spark”](#).

Utilisation des connexions MongoDB dans les tâches ETL

Vous pouvez créer une connexion pour MongoDB, puis utiliser cette connexion dans votre AWS Glue travail. Pour plus d'informations, consultez [the section called “Connexions MongoDB”](#) le guide AWS Glue de programmation. Les connexions `url`, `username` et `password` sont stockées dans la connexion MongoDB. D'autres options peuvent être spécifiées dans votre script de tâche ETL à l'aide

du paramètre `additionalOptions` de `glueContext.getCatalogSource`. Les autres options peuvent inclure :

- `database`: (Obligatoire) La base de données MongoDB à lire.
- `collection` : (Obligatoire) La collection MongoDB à lire.

En plaçant les informations `database` et `collection` dans le script de tâche ETL, vous pouvez utiliser la même connexion pour plusieurs tâches.

1. Créez une AWS Glue Data Catalog connexion pour la source de données MongoDB. Consultez ["connectionType": "mongodb"](#) pour obtenir une description des paramètres de connexion. Vous pouvez créer la connexion à l'aide de la console APIs ou de la CLI.
2. Créez une base de données dans le AWS Glue Data Catalog pour stocker les définitions de table pour vos données MongoDB. Pour plus d'informations, consultez [Création de bases de données](#).
3. Créez un crawler qui explore les données dans MongoDB en utilisant les informations de la connexion pour se connecter à MongoDB. Le robot crée les tables AWS Glue Data Catalog qui décrivent les tables de la base de données MongoDB que vous utilisez dans le cadre de votre travail. Pour plus d'informations, consultez [Utilisation de robots d'exploration pour alimenter le catalogue de données](#).
4. Créez une tâche avec un script personnalisé. Vous pouvez créer la tâche à l'aide de la console APIs ou de la CLI. Pour plus d'informations, voir [Ajouter des tâches dans AWS Glue](#).
5. Choisissez les cibles de données de votre tâche. Les tables qui représentent les données cible peuvent être définies dans votre catalogue de données ou votre tâche peut créer les tables cible lors son exécution. Vous choisissez un emplacement cible lorsque vous créez la tâche. Si la cible nécessite une connexion, la connexion est également référencée dans votre tâche. Si votre tâche nécessite plusieurs cibles de données, vous pouvez les ajouter ensuite en modifiant le script.
6. Personnalisez l'environnement de traitement de tâche en fournissant des arguments pour votre tâche et le script généré.

Voici un exemple de création de `DynamicFrame` à partir de la base de données MongoDB basée sur la structure de table définie dans le catalogue de données. Le code utilise `additionalOptions` pour fournir les informations supplémentaires sur la source de données :

Scala

```
val resultFrame: DynamicFrame = glueContext.getCatalogSource(  
    database = catalogDB,  
    tableName = catalogTable,  
    additionalOptions = JsonOptions(Map("database" -> DATABASE_NAME,  
        "collection" -> COLLECTION_NAME))  
).getDynamicFrame()
```

Python

```
glue_context.create_dynamic_frame_from_catalog(  
    database = catalogDB,  
    table_name = catalogTable,  
    additional_options = {"database": "database_name",  
        "collection": "collection_name"})
```

7. Exécutez la tâche, à la demande ou via un déclencheur..

Optimisation des performances des requêtes à l'aide des statistiques des colonnes

Vous pouvez calculer des statistiques au niveau des colonnes pour AWS Glue Data Catalog des tables dans des formats de données tels que Parquet, ORC, JSON, ION, CSV et XML sans configurer de pipelines de données supplémentaires. Les statistiques de colonne vous aident à comprendre les profils de données en obtenant des informations sur les valeurs d'une colonne.

Le catalogue de données prend en charge la génération de statistiques pour les valeurs de colonne telles que la valeur minimale, la valeur maximale, le total des valeurs nulles, le total des valeurs distinctes, la longueur moyenne des valeurs et le nombre total d'occurrences de valeurs vraies. AWS des services analytiques tels qu'Amazon Redshift et Amazon Athena peuvent utiliser ces statistiques de colonne pour générer des plans d'exécution des requêtes et choisir le plan optimal qui améliore les performances des requêtes.

Il existe trois scénarios pour générer des statistiques sur les colonnes :

Automatique

AWS Glue prend en charge la génération automatique de statistiques sur les colonnes au niveau du catalogue afin de pouvoir générer automatiquement des statistiques pour les nouvelles tables du AWS Glue Data Catalog

Programmé

AWS Glue prend en charge la génération de statistiques de colonne de planification afin qu'elle puisse être exécutée automatiquement selon un calendrier récurrent.

Avec le calcul planifié des statistiques, la tâche de statistiques sur les colonnes met à jour les statistiques globales au niveau de la table, telles que min, max et avg, avec les nouvelles statistiques, fournissant aux moteurs de requêtes des statistiques précises et up-to-date permettant d'optimiser l'exécution des requêtes.

À la demande

Utilisez cette option pour générer des statistiques de colonnes à la demande chaque fois que cela est nécessaire. Cela est utile pour les analyses ad hoc ou lorsque les statistiques doivent être calculées immédiatement.

Vous pouvez configurer pour exécuter une tâche de génération de statistiques de colonne à l'aide des AWS CLI opérations de AWS Glue console et AWS Glue d'API. Lorsque vous lancez le processus, AWS Glue démarre une tâche Spark en arrière-plan et met à jour les métadonnées de la AWS Glue table dans le catalogue de données. Vous pouvez consulter les statistiques des colonnes à l'aide de la AWS Glue console AWS CLI ou en appelant l'opération [GetColumnStatisticsForTableAPI](#).

Note

Si vous utilisez les autorisations de Lake Formation pour contrôler l'accès à la table, le rôle assumé par la tâche de statistiques de colonne nécessite un accès complet à la table pour générer des statistiques.

Rubriques

- [Conditions préalables à la génération de statistiques de colonne](#)
- [Génération automatique de statistiques sur les colonnes](#)
- [Génération de statistiques sur les colonnes selon un calendrier](#)

- [Génération de statistiques de colonnes à la demande](#)
- [Affichage des statistiques de colonne](#)
- [Affichage des exécutions de tâches de statistiques de colonne](#)
- [Arrêt d'exécution de la tâche de statistiques de colonne](#)
- [Supprimer les statistiques de colonne](#)
- [Considérations et restrictions](#)

Conditions préalables à la génération de statistiques de colonne

Pour générer ou mettre à jour les statistiques de colonne, la tâche de génération de statistiques assume un rôle (IAM) AWS Identity and Access Management en votre nom. Sur la base des autorisations accordées au rôle, la tâche de génération de statistiques de colonne peut lire les données à partir du magasin de données Amazon S3.

Lorsque vous configurez la tâche de génération de statistiques de AWS Glue colonne, vous pouvez créer un rôle qui inclut la politique `AWSGlueServiceRole` AWS gérée ainsi que la politique en ligne requise pour la source de données spécifiée.

Si vous spécifiez un rôle existant pour générer des statistiques de colonne, assurez-vous qu'il inclut la `AWSGlueServiceRole` politique ou un équivalent (ou une version réduite de cette politique), ainsi que les politiques intégrées requises. Pour créer un nouveau rôle IAM, procédez comme suit :

Note

Pour générer des statistiques pour les tables gérées par Lake Formation, le rôle IAM utilisé pour générer des statistiques nécessite un accès complet à la table.

Lorsque vous configurez la tâche de génération de statistiques de AWS Glue colonne, vous pouvez créer un rôle qui inclut la politique `AWSGlueServiceRole` AWS gérée ainsi que la politique en ligne requise pour la source de données spécifiée. Vous pouvez également créer un rôle et associer les autorisations répertoriées dans la politique ci-dessous, puis ajouter ce rôle à la tâche de génération des statistiques de colonne.

Pour créer un rôle IAM pour générer des statistiques de colonne

1. Pour créer un rôle IAM, consultez [Création d'un rôle IAM pour AWS Glue](#).

2. Pour mettre à jour un rôle existant, dans la console IAM, accédez au rôle IAM utilisé par le processus de génération de statistiques de colonne.
3. Dans la section Ajouter des autorisations, choisissez Attacher des stratégies. Dans la nouvelle fenêtre du navigateur, choisissez la politique AWSGlueServiceRole AWS gérée.
4. Vous devez également inclure les autorisations pour lire les données à partir de l'emplacement de données Amazon S3.

Dans la section Ajouter des autorisations, choisissez Créer une stratégie. Dans la fenêtre du navigateur nouvellement ouverte, créez une nouvelle stratégie à utiliser avec votre rôle.

5. Sur la page Créer une stratégie, choisissez l'onglet JSON. Copiez le code JSON suivant dans le champ de l'éditeur de stratégie.

 Note

Dans les politiques suivantes, remplacez l'ID de compte par un identifiant valide Compte AWS, puis `region` remplacez-le par la région du tableau et `bucket-name` par le nom du compartiment Amazon S3.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "S3BucketAccess",
      "Effect": "Allow",
      "Action": [
        "s3:ListBucket",
        "s3:GetObject"
      ],
      "Resource": [
        "arn:aws:s3:::<bucket-name>/*",
        "arn:aws:s3:::<bucket-name>"
      ]
    }
  ]
}
```

6. (Facultatif) Si vous utilisez les autorisations Lake Formation pour accéder à vos données, le rôle IAM nécessite des autorisations `lakeformation:GetDataAccess`.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "LakeFormationDataAccess",
      "Effect": "Allow",
      "Action": "lakeformation:GetDataAccess",
      "Resource": [
        "*"
      ]
    }
  ]
}
```

Si l'emplacement des données Amazon S3 est enregistré auprès de Lake Formation et que le rôle IAM assumé par la tâche de génération de statistiques de colonne ne dispose pas d'autorisations de groupe IAM_ALLOWED_PRINCIPALS accordées sur la table, le rôle nécessite Lake Formation ALTER et des autorisations DESCRIBE sur la table. Le rôle utilisé pour enregistrer le compartiment Amazon S3 nécessite Lake Formation INSERT et des autorisations DELETE sur la table.

Si l'emplacement des données Amazon S3 n'est pas enregistré auprès de Lake Formation et que le rôle IAM ne dispose pas d'autorisations de groupe IAM_ALLOWED_PRINCIPALS accordées sur la table, le rôle nécessite les autorisations Lake Formation ALTER, DESCRIBE, INSERT et DELETE sur la table.

7. Si vous avez activé l'`Automatic statistics generationoption` au niveau du catalogue, le rôle IAM doit disposer de l'`glue:UpdateCatalogautorisation` ou de l'autorisation Lake Formation ALTER CATALOG sur le catalogue de données par défaut. Vous pouvez utiliser cette `GetCatalog` opération pour vérifier les propriétés du catalogue.
8. (Facultatif) La tâche de génération de statistiques de colonne qui écrit Amazon CloudWatch Logs chiffré nécessite les autorisations suivantes dans la stratégie de clé.

```
{
  "Version": "2012-10-17",
  "Statement": [{
    "Sid": "CWLogsKmsPermissions",
    "Effect": "Allow",
```

```

    "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents",
        "logs:AssociateKmsKey"
    ],
    "Resource": [
        "arn:aws:logs:<region>:111122223333:log-group:/aws-glue:*"
    ]
},
{
    "Sid": "KmsPermissions",
    "Effect": "Allow",
    "Action": [
        "kms:GenerateDataKey",
        "kms:Decrypt",
        "kms:Encrypt"
    ],
    "Resource": [
        "arn:aws:kms:<region>:111122223333:key/"arn of key used for ETL cloudwatch
        encryption"
    ],
    "Condition": {
        "StringEquals": {
            "kms:ViaService": ["glue.<region>.amazonaws.com"]
        }
    }
}
]
}

```

9. Le rôle que vous utilisez pour exécuter les statistiques des colonnes doit disposer de l'`iam:PassRole` autorisation correspondante.

```

{
    "Version": "2012-10-17",
    "Statement": [{
        "Effect": "Allow",
        "Action": [
            "iam:PassRole"
        ],
        "Resource": [

```



```

        "arn:aws:iam::111122223333:role/<columnstats-role-name>"
    ]
  }]
}

```

10. Lorsque vous créez un rôle IAM pour générer des statistiques de colonne, ce rôle doit également avoir la stratégie d'approbation suivante qui permet au service d'assumer le rôle.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "TrustPolicy",
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole",
    }
  ]
}

```

Génération automatique de statistiques sur les colonnes

La génération automatique de statistiques de colonnes vous permet de planifier et de calculer automatiquement les statistiques sur les nouvelles tables du AWS Glue Data Catalog. Lorsque vous activez la génération automatique de statistiques, le catalogue de données découvre de nouvelles tables avec des formats de données spécifiques tels que Parquet, JSON, CSV, XML, ORC, ION et Apache Iceberg, ainsi que leurs chemins de compartiment individuels. Avec une configuration de catalogue unique, le catalogue de données génère des statistiques pour ces tables.

Les administrateurs de Data Lake peuvent configurer la génération de statistiques en sélectionnant le catalogue par défaut dans la console Lake Formation et en activant les statistiques des tables à l'aide de `Optimization configuration` cette option. Lorsque vous créez de nouvelles tables ou que vous mettez à jour des tables existantes dans le catalogue de données, le catalogue de données collecte le nombre de valeurs distinctes (NDVs) pour les tables Apache Iceberg, ainsi que des statistiques supplémentaires telles que le nombre de valeurs nulles, la longueur maximale, minimale et moyenne pour les autres formats de fichiers pris en charge sur une base hebdomadaire.

Si vous avez configuré la génération de statistiques au niveau de la table ou si vous avez précédemment supprimé les paramètres de génération de statistiques d'une table, ces paramètres spécifiques à la table ont priorité sur les paramètres de catalogue par défaut pour la génération automatique de statistiques de colonnes.

La tâche de génération automatique de statistiques analyse 50 % des enregistrements des tables pour calculer les statistiques. La génération automatique de statistiques par colonne garantit que le catalogue de données conserve des métriques hebdomadaires qui peuvent être utilisées par les moteurs de requêtes tels qu'Amazon Athena et Amazon Redshift Spectrum pour améliorer les performances des requêtes et réaliser des économies de coûts potentielles. Il permet de planifier la génération de statistiques à l'aide AWS Glue APIs de la console, fournissant ainsi un processus automatisé sans intervention manuelle.

Rubriques

- [Activation de la génération automatique de statistiques au niveau du catalogue](#)
- [Affichage des paramètres automatisés au niveau de la table](#)
- [Désactivation de la génération de statistiques de colonnes au niveau du catalogue](#)

Activation de la génération automatique de statistiques au niveau du catalogue

Vous pouvez activer la génération automatique de statistiques de colonne pour toutes les nouvelles tables Apache Iceberg et les tables dans des formats de table autres que OTF (Parquet, JSON, CSV, XML, ORC, ION) dans le catalogue de données. Après avoir créé la table, vous pouvez également mettre à jour manuellement de manière explicite les paramètres des statistiques des colonnes.

Pour mettre à jour les paramètres du catalogue de données afin de les activer au niveau du catalogue, le rôle IAM utilisé doit disposer de `glue:UpdateCatalogautorisation` ou de l' AWS Lake Formation `ALTER CATALOGautorisation` sur le catalogue racine. Vous pouvez utiliser l'`GetCatalogAPI` pour vérifier les propriétés du catalogue.

AWS Management Console

Pour activer la génération automatique de statistiques par colonne au niveau du compte

1. Ouvrez la console Lake Formation à l'adresse <https://console.aws.amazon.com/lakeformation/>.
2. Dans la barre de navigation de gauche, sélectionnez Catalogues.
3. Sur la page de résumé du catalogue, choisissez Modifier sous Configuration de l'optimisation.

Catalog summary

Name 489977581737	Data encryption -	IAM role -
Catalog ARN arn:aws:glue:us-east-2:::catalog		KMS key for optimization -

Table statistics
Manage and edit table statistics and optimizations. [View pricing](#)

Table statistics
 On

IAM role
[AWSGlueServiceRole-crawler-test-role](#)

Actions

- Delete
- Edit
- Server-side filtering
- Permissions
- Grant
- Revoke
- Verify
- View
- Optimization configuration
- Edit

- Sur la page de configuration de l'optimisation des tables, choisissez l'option Activer la génération automatique de statistiques pour les tables du catalogue.

Edit optimization configuration

Table statistics
Manage and edit table statistics and optimizations. [View pricing](#)

☒ Enable automatic statistics generation for the tables of the catalog

IAM role
Choose a role that has permissions to invoke an AWS Glue connector.

[Create new IAM role](#) [View](#) [Refresh](#)

- Choisissez un rôle IAM existant ou créez-en un nouveau doté des autorisations nécessaires pour exécuter la tâche de statistiques de colonne.
- Sélectionnez Envoyer.

AWS CLI

Vous pouvez également activer la collecte de statistiques au niveau du catalogue via le. AWS CLI Pour configurer la collecte de statistiques au niveau des tables à l'aide de AWS CLI, exécutez la commande suivante :

```
aws glue update-catalog --cli-input-json '{
  "name": "123456789012",
  "catalogInput": {
    "description": "Updating root catalog with role arn",
    "catalogProperties": {
      "customProperties": {
```

```

        "ColumnStatistics.RoleArn": "arn:aws:iam::"123456789012":role/
service-role/AWSGlueServiceRole",
        "ColumnStatistics.Enabled": "true"
    }
}
}'

```

La commande ci-dessus appelle AWS Glue l'UpdateCatalogopération, qui prend en compte une CatalogProperties structure avec les paires clé-valeur suivantes pour la génération de statistiques au niveau du catalogue :

- ColumnStatistics.RoleArn — L'ARN du rôle IAM doit être utilisé pour toutes les tâches déclenchées pour la génération de statistiques au niveau du catalogue
- ColumnStatistics.Enabled — Booléen indiquant si les paramètres au niveau du catalogue sont activés ou désactivés

Affichage des paramètres automatisés au niveau de la table

Lorsque la collecte de statistiques au niveau du catalogue est activée, chaque fois qu'une table Apache Hive ou Apache Iceberg est créée ou mise à jour via le SDK CreateTable ou UpdateTable APIs qu'un paramètre de niveau de table équivalent est créé pour cette table. AWS Management Console AWS Glue crawler

Les tables pour lesquelles la génération automatique de statistiques est activée doivent respecter l'une des propriétés suivantes :

- Utilisez un InputSerdeLibrary nom commençant par org.apache.hadoop et égal à TableType EXTERNAL_TABLE
- Utilisez un InputSerdeLibrary qui commence par com.amazon.ion et TableType est égal à EXTERNAL_TABLE
- Contient table_type : « ICEBERG » dans sa structure de paramètres.

Après avoir créé ou mis à jour une table, vous pouvez vérifier les détails de la table pour confirmer la génération des statistiques. Statistics generation summaryIndique que la Schedule propriété est définie comme telle AUTO et que Statistics configuration sa

valeur estInherited from catalog. Tout paramètre de table avec le paramètre suivant serait automatiquement déclenché par Glue en interne.

catalog_page

Last updated (UTC)
November 26, 2024 at 03:11:02

Version 2 (Current version)

Actions

Table overview

Data quality - new

Table details

Name

catalog_page

Database

tpcdsdb

Description

-

Last updated

November 26, 2024 at 02:56:48

Classification

Parquet

Location

s3://blogpost-sparkoneks-us-east-1/blog/BLOG_TPCDS-TEST-3T-partitioned/catalog_page/

Connection

-

Deprecated

-

Column statistics

🟢 Last updated: November 26, 2024 at 03:10:17

► Advanced properties

Schema

Partitions

Indexes

Column statistics - new

Statistics generation summary

Generate column statistics for the full table, either on a schedule or on demand. Only one scheduled run can be active at any given time.

Schedule

Auto

Statistics last updated

November 26, 2024 at 03:10:17

Statistics last update status

🟢 Succeeded

Statistics configuration

Inherited from catalog

Statistics last started

November 26, 2024 at 03:06:30

Task run id

-

Error message

-

ActionsView all runsGenerate

Column statistics (9) Info

Last updated (UTC)
November 26, 2024 at 03:20:11

Get an overview of the data profile. We estimate the approximate number of distinct values in a data set with 5% average relative error.

Find columns

< 1 >

Column name	Last update...	Average length	Distinct values	Max length	Null values	Max value	Min value	True values	False values
cp_catalog_number	November 26, 2024	-	62	-	0	108	1	-	-
cp_catalog_page_id	November 26, 2024	16.00	81	16	0	-	-	-	-
cp_catalog_page_numl	November 26, 2024	-	72	-	0	333	13	-	-
cp_catalog_page_sk	November 26, 2024	-	81	-	0	35704	293	-	-
cp_department	November 26, 2024	10.00	1	10	0	-	-	-	-
cp_description	November 26, 2024	72.43	82	99	0	-	-	-	-
cp_end_date_sk	November 26, 2024	-	59	-	0	2453003	2450904	-	-
cp_start_date_sk	November 26, 2024	-	55	-	0	2452970	2450815	-	-
cp_type	November 26, 2024	7.75	3	9	0	-	-	-	-

Désactivation de la génération de statistiques de colonnes au niveau du catalogue

Vous pouvez désactiver la génération automatique de statistiques de colonne pour les nouvelles tables à l'aide de la AWS Lake Formation console, de l'glue:UpdateCatalogSettingsAPI ou de l'glue>DeleteColumnStatisticsTaskSettingsAPI.

Pour désactiver la génération automatique de statistiques par colonne au niveau du compte

- Ouvrez la console Lake Formation à l'adresse <https://console.aws.amazon.com/lakeformation/>.
- Dans la barre de navigation de gauche, sélectionnez Catalogues.
- Sur la page de résumé du catalogue, choisissez Modifier sous Configuration de l'optimisation.
- Sur la page de configuration de l'optimisation des tables, désélectionnez l'option Activer la génération automatique de statistiques pour les tables du catalogue.

Optimisation des performances des requêtes à l'aide des statistiques des colonnes

267

5. Sélectionnez Envoyer.

Génération de statistiques sur les colonnes selon un calendrier

Suivez ces étapes pour configurer un calendrier de génération de statistiques de colonne à l' AWS Glue Data Catalog aide de la AWS Glue console, de l' AWS CLI opération ou de l'[CreateColumnStatisticsTaskSettings](#)opération.

Console

Pour générer des statistiques de colonne à l'aide de la console

1. Connectez-vous à la AWS Glue console à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez des tables du catalogue de donnée.
3. Choisissez une table dans la liste.
4. Choisissez l'onglet Statistiques des colonnes dans la section inférieure de la page Tables.
5. Vous pouvez également sélectionner Générer selon le calendrier sous Statistiques des colonnes depuis Actions.
6. Sur la page Générer des statistiques selon le calendrier, configurez un calendrier récurrent pour exécuter la tâche de statistiques sur les colonnes en choisissant la fréquence et l'heure de début. Vous pouvez choisir une fréquence horaire, quotidienne, hebdomadaire ou définir une expression cron pour spécifier le calendrier.

Une expression cron est une chaîne représentant un modèle de planification, composée de 6 champs séparés par des espaces : * * * * * <minute><hour><day of month><month><day of week><year> Par exemple, pour exécuter une tâche tous les jours à minuit, l'expression cron serait : 0 0 * * ? *

Pour plus d'informations, consultez la section [Expressions Cron](#).

Generate statistics on schedule [Info](#)

Generate column statistics for the table to improve query performance and potentially save costs. [View pricing](#)

Schedule

Set a schedule for the statistics generation job by choosing the frequency and time.

Frequency

Weekly

Days

Select the days of the week to run your job.

☐ Mon ☐ Tue ☐ Wed ☒ Thu ☐ Fri ☐ Sat ☐ Sun

Start time

Enter the time (UTC) of the day for when the job will run.

17:13

Use 24-hour format (hh:mm).

Column options



All columns

Generate statistics for all columns.



Selected columns

Choose the columns to generate statistics.

IAM Role

Column statistics task requires permissions to read Data Catalog tables and underlying data in the S3 bucket.

IAM role



Create new IAM role



Use an existing IAM role

New IAM role

ColumnStatisticsRole-sales

[View permission details](#)

► **Advanced configuration - optional**

[Cancel](#)

[Generate statistics](#)

7. Ensuite, choisissez l'option de colonne pour générer des statistiques.
 - Toutes les colonnes — Choisissez cette option pour générer des statistiques pour toutes les colonnes du tableau.
 - Colonnes sélectionnées : choisissez cette option pour générer des statistiques pour des colonnes spécifiques. Vous pouvez sélectionner les colonnes dans la liste déroulante.
8. Choisissez un rôle IAM ou créez un rôle existant autorisé à générer des statistiques. AWS Glue assume ce rôle pour générer des statistiques de colonne.

Une approche plus rapide consiste à laisser la AWS Glue console créer un rôle pour vous. Le rôle qu'il crée est spécifiquement destiné à générer des statistiques sur les colonnes et inclut la politique `AWSGlueServiceRole` AWS gérée ainsi que la politique en ligne requise pour la source de données spécifiée.

Si vous spécifiez un rôle existant pour générer des statistiques de colonne, assurez-vous qu'il inclut la `AWSGlueServiceRole` politique ou un équivalent (ou une version réduite de cette politique), ainsi que les politiques intégrées requises.

9. (Facultatif) Choisissez ensuite une configuration de sécurité pour activer le chiffrement au repos des journaux.
10. (Facultatif) Vous pouvez choisir une taille d'échantillon en indiquant uniquement un pourcentage spécifique de lignes du tableau pour générer des statistiques. La valeur par défaut est toutes les lignes. Utilisez les flèches haut et bas pour augmenter ou diminuer la valeur en pourcentage.

Nous vous recommandons d'inclure toutes les lignes de la table pour calculer des statistiques précises. Utilisez des exemples de lignes pour générer des statistiques de colonne uniquement lorsque des valeurs approximatives sont acceptables.

11. Choisissez Générer des statistiques pour exécuter la tâche de génération des statistiques de colonne.

AWS CLI

Vous pouvez utiliser l' AWS CLI exemple suivant pour créer un calendrier de génération de statistiques de colonnes. Le nom de la base de données, le nom de la table et le rôle sont des paramètres obligatoires, tandis que les paramètres facultatifs sont le planning, l'identifiant du catalogue `column-name-list`, la taille de l'échantillon et la configuration de sécurité.

```
aws glue create-column-statistics-task-settings \  
  --database-name 'database_name' \  
  --table-name table_name \  
  --role 'arn:aws:iam::123456789012:role/stats-role' \  
  --schedule 'cron(0 0-5 14 * * ?)' \  
  --column-name-list 'col-1' \  
  --catalog-id '123456789012' \  
  --sample-size '10.0' \  
  --security-configuration 'test-security'
```

Vous pouvez également générer des statistiques de colonne en appelant l'[StartColumnStatisticsTaskRun](#) opération.

Gestion du calendrier de génération des statistiques des colonnes

Vous pouvez gérer les opérations de planification telles que la mise à jour, le démarrage, l'arrêt et la suppression des planifications pour les statistiques de colonne générées dans AWS Glue. Vous pouvez utiliser les [opérations de l'API de statistiques de AWS Glue console ou de AWS Glue colonne](#) pour effectuer ces tâches. AWS CLI

Rubriques

- [Mettre à jour le calendrier de génération des statistiques des colonnes](#)
- [Arrêt du calendrier de génération des statistiques des colonnes](#)
- [Reprise du calendrier pour la génération des statistiques des colonnes](#)
- [Supprimer le calendrier de génération des statistiques des colonnes](#)

Mettre à jour le calendrier de génération des statistiques des colonnes

Vous pouvez mettre à jour le calendrier pour déclencher la tâche de génération des statistiques de colonne après sa création. Vous pouvez utiliser la AWS Glue console ou exécuter l'[UpdateColumnStatisticsTaskSettings](#) opération pour mettre à jour le calendrier d'une table. AWS CLI Vous pouvez modifier les paramètres d'une planification existante, tels que le type de planification (à la demande ou planifiée) et d'autres paramètres facultatifs.

AWS Management Console

Pour mettre à jour les paramètres d'une tâche de génération de statistiques de colonne

1. Connectez-vous à la AWS Glue console à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez la table que vous souhaitez mettre à jour dans la liste des tables.
3. Dans la partie inférieure de la page de détails du tableau, sélectionnez Statistiques de colonne.
4. Sous Actions, choisissez Modifier pour mettre à jour le calendrier.
5. Apportez les modifications souhaitées au calendrier, puis choisissez Enregistrer.

AWS CLI

Si vous n'utilisez pas la fonction AWS Glue de génération de statistiques de la console, vous pouvez mettre à jour le calendrier manuellement à l'aide de la `update-column-statistics-`

task-settings commande. L'exemple suivant montre comment mettre à jour les statistiques de colonne à l'aide de la AWS CLI.

```
aws glue update-column-statistics-task-settings \  
  --database-name 'database_name' \  
  --table-name 'table_name' \  
  --role arn:aws:iam::123456789012:role/stats_role \  
  --schedule 'cron(0 0-5 16 * * ?)' \  
  --column-name-list 'col-1' \  
  --sample-size '20.0' \  
  --catalog-id '123456789012' \  
  --security-configuration 'test-security'
```

Arrêt du calendrier de génération des statistiques des colonnes

Si vous n'avez plus besoin des statistiques incrémentielles, vous pouvez arrêter la génération planifiée pour économiser des ressources et des coûts. La suspension du calendrier n'a aucune incidence sur les statistiques générées précédemment. Vous pouvez reprendre l'horaire à votre convenance.

AWS Management Console

Pour arrêter le calendrier d'une tâche de génération de statistiques de colonnes

1. Sur AWS Glue la console, sélectionnez Tables sous Catalogue de données.
2. Sélectionnez une table avec des statistiques de colonne.
3. Sur la page Détails de la table, choisissez Statistiques de colonne.
4. Sous Actions, choisissez Génération planifiée, puis Pause.
5. Choisissez Pause pour confirmer.

AWS CLI

Pour arrêter le calendrier d'exécution d'une tâche de statistiques de colonne à l'aide de AWS CLI, vous pouvez utiliser la commande suivante :

```
aws glue stop-column-statistics-task-run-schedule \  
  --database-name 'database_name' \  
  --table-name 'table_name'
```

Remplacez le `database_name` et `table_name` par les noms réels de la base de données et de la table pour lesquelles vous souhaitez arrêter le calendrier d'exécution de la tâche de statistiques sur les colonnes.

Reprise du calendrier pour la génération des statistiques des colonnes

Si vous avez suspendu le calendrier de génération des statistiques, vous AWS Glue permet de le reprendre à votre convenance. Vous pouvez reprendre le planning à l'aide de la AWS Glue AWS CLI console ou de l'[StartColumnStatisticsTaskRunSchedule](#) opération.

AWS Management Console

Pour reprendre le calendrier de génération des statistiques des colonnes

1. Sur AWS Glue la console, sélectionnez Tables sous Catalogue de données.
2. Sélectionnez une table avec des statistiques de colonne.
3. Sur la page Détails de la table, choisissez Statistiques de colonne.
4. Sous Actions, sélectionnez Génération planifiée, puis Reprise.
5. Choisissez Resume pour confirmer.

AWS CLI

Remplacez le `database_name` et `table_name` par les noms réels de la base de données et de la table pour lesquelles vous souhaitez arrêter le calendrier d'exécution de la tâche de statistiques sur les colonnes.

```
aws glue start-column-statistics-task-run-schedule \  
  --database-name 'database_name' \  
  --table-name 'table_name'
```

Supprimer le calendrier de génération des statistiques des colonnes

Bien que la gestion up-to-date des statistiques soit généralement recommandée pour optimiser les performances des requêtes, il existe des cas d'utilisation spécifiques dans lesquels la suppression du calendrier de génération automatique peut être bénéfique.

- Si les données restent relativement statiques, les statistiques des colonnes existantes peuvent rester précises pendant une période prolongée, ce qui réduit le besoin de mises à jour fréquentes. La suppression de la planification permet d'éviter la consommation inutile de ressources et les frais généraux associés à la régénération des statistiques sur des données immuables.
- Lorsque le contrôle manuel de la génération de statistiques est préférable. En supprimant le calendrier automatique, les administrateurs peuvent mettre à jour de manière sélective les statistiques des colonnes à des intervalles spécifiques ou après des modifications importantes des données, en alignant le processus sur leurs stratégies de maintenance et leurs besoins d'allocation de ressources.

AWS Management Console

Pour supprimer le calendrier de génération des statistiques des colonnes

1. Sur AWS Glue la console, sélectionnez Tables sous Catalogue de données.
2. Sélectionnez une table avec des statistiques de colonne.
3. Sur la page Détails de la table, choisissez Statistiques de colonne.
4. Sous Actions, sélectionnez Génération planifiée, puis Supprimer.
5. Choisissez Supprimer pour confirmer.

AWS CLI

Remplacez le `database_name` et `table_name` par les noms réels de la base de données et de la table pour lesquelles vous souhaitez arrêter le calendrier d'exécution de la tâche de statistiques sur les colonnes.

Vous pouvez supprimer le calendrier des statistiques des colonnes à l'aide de l'opération [DeleteColumnStatisticsTaskSettings](#) API ou AWS CLI. L'exemple suivant montre comment supprimer le calendrier de génération des statistiques de colonne à l'aide de AWS Command Line Interface (AWS CLI).

```
aws glue delete-column-statistics-task-settings \  
  --database-name 'database_name' \  
  --table-name 'table_name'
```

Génération de statistiques de colonnes à la demande

Vous pouvez exécuter la tâche de statistiques de colonnes pour la tâche de AWS Glue Data Catalog tables à la demande sans planification définie. Cette option est utile pour les analyses ad hoc ou lorsque les statistiques doivent être calculées immédiatement.

Procédez comme suit pour générer des statistiques de colonne à la demande pour les tables du catalogue de données à l'aide de AWS Glue la console ou AWS CLI.

AWS Management Console

Pour générer des statistiques de colonne à l'aide de la console

1. Connectez-vous à la AWS Glue console à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez des tables du catalogue de donnée.
3. Choisissez une table dans la liste.
4. Choisissez Générer des statistiques dans le menu Actions.

Vous pouvez également choisir l'option Générer, générer à la demande sous l'onglet Statistiques des colonnes dans la section inférieure de la page Table.

5. Suivez les étapes 7 à 11 [Génération de statistiques sur les colonnes selon un calendrier](#) pour générer des statistiques de colonne pour le tableau.
6. Sur la page Générer des statistiques, spécifiez les options suivantes :

Generate statistics on demand [Info](#)

Generate column statistics for the table to improve query performance and potentially save costs. [View pricing](#)

Column options☒ **All columns**

Generate statistics for all columns.

☐ **Selected columns**

Choose the columns to generate statistics.

IAM Role

Column statistics task requires permissions to read Data Catalog tables and underlying data in the S3 bucket.

IAM role

☐ Create new IAM role

☒ Use an existing IAM role

Existing IAM role

Choose an IAM role



[View](#)

▼ Advanced configuration - optional**Security configuration**

Choose a security configuration to enable at-rest encryption on the logs pushed to CloudWatch.

Sample rows

The percentage of rows to sample.

%

Between 0 and 100. Leave blank if using all rows.

[Cancel](#)

[Generate statistics](#)

- **Toutes les colonnes** — Choisissez cette option pour générer des statistiques pour toutes les colonnes du tableau.
- **Colonnes sélectionnées** : choisissez cette option pour générer des statistiques pour des colonnes spécifiques. Vous pouvez sélectionner les colonnes dans la liste déroulante.
- **Rôle IAM** — Choisissez Créer un nouveau rôle IAM doté des politiques d'autorisation requises pour exécuter la tâche de génération des statistiques de colonne. Choisissez Afficher les détails des autorisations pour consulter la déclaration de politique. Vous pouvez également sélectionner un rôle IAM dans la liste. Pour plus d'informations sur les autorisations requises, consultez [Conditions préalables à la génération de statistiques de colonne](#).

AWS Glue assume les autorisations du rôle que vous spécifiez pour générer des statistiques.

Pour plus d'informations sur la fourniture de rôles pour AWS Glue, consultez la section [Politiques basées sur l'identité](#) pour AWS Glue.

- (Facultatif) Choisissez ensuite une configuration de sécurité pour activer le chiffrement au repos des journaux.

- Exemples de lignes : choisissez uniquement un pourcentage spécifique de lignes dans la table pour générer des statistiques. La valeur par défaut est toutes les lignes. Utilisez les flèches haut et bas pour augmenter ou diminuer la valeur en pourcentage.

 Note

Nous vous recommandons d'inclure toutes les lignes de la table pour calculer des statistiques précises. Utilisez des exemples de lignes pour générer des statistiques de colonne uniquement lorsque des valeurs approximatives sont acceptables.

Choisissez Générer des statistiques pour exécuter la tâche.

AWS CLI

Cette commande déclenchera l'exécution d'une tâche de statistiques de colonne pour la table spécifiée. Vous devez fournir le nom de la base de données, le nom de la table, un rôle IAM autorisé à générer des statistiques, et éventuellement fournir des noms de colonnes et un pourcentage de taille d'échantillon pour le calcul des statistiques.

```
aws glue start-column-statistics-task-run \  
  --database-name 'database_name' \  
  --table-name 'table_name' \  
  --role 'arn:aws:iam::123456789012:role/stats-role' \  
  --column-name 'col1', 'col2' \  
  --sample-size 10.0
```

Cette commande lancera une tâche visant à générer des statistiques de colonne pour la table spécifiée.

Mise à jour des statistiques des colonnes à la demande

La gestion des statistiques des up-to-date colonnes est essentielle pour que l'optimiseur de requêtes génère des plans d'exécution efficaces, garantissant des performances de requête améliorées, une consommation de ressources réduite et de meilleures performances globales du système. Ce processus est particulièrement important après des modifications importantes des données, telles

que des chargements groupés ou des modifications importantes, qui peuvent rendre les statistiques existantes obsolètes.

Vous devez exécuter explicitement la tâche Générer des statistiques depuis la AWS Glue console pour actualiser les statistiques des colonnes. Le catalogue de données n'actualise pas automatiquement les statistiques.

Si vous n'utilisez pas la fonction AWS Glue de génération de statistiques de la console, vous pouvez mettre à jour manuellement les statistiques des colonnes à l'aide de l'opération [UpdateColumnStatisticsForTable](#) API ou AWS CLI. L'exemple suivant montre comment mettre à jour les statistiques de colonne à l'aide de la AWS CLI.

```
aws glue update-column-statistics-for-table --cli-input-json:
```

```
{
  "CatalogId": "111122223333",
  "DatabaseName": "database_name",
  "TableName": "table_name",
  "ColumnStatisticsList": [
    {
      "ColumnName": "col1",
      "ColumnType": "Boolean",
      "AnalyzedTime": "1970-01-01T00:00:00",
      "StatisticsData": {
        "Type": "BOOLEAN",
        "BooleanColumnStatisticsData": {
          "NumberOfTrues": 5,
          "NumberOfFalses": 5,
          "NumberOfNulls": 0
        }
      }
    }
  ]
}
```

Affichage des statistiques de colonne

Une fois les statistiques générées avec succès, Data Catalog stocke ces informations pour les optimiseurs basés sur les coûts Amazon Athena et Amazon Redshift afin de faire des choix optimaux lors de l'exécution de requêtes. Les statistiques varient en fonction du type de colonne.

AWS Management Console

Pour afficher les statistiques de colonne d'une table

- Après avoir exécuté la tâche de statistiques de colonne, l'onglet Statistiques de colonne de la page Détails de la table affiche les statistiques pour la table.

AWS Glue > Tables > pentest_orders_xml

pentest_orders_xml

Last updated (UTC)
October 25, 2023 at 19:14:47

Version 15 (Current version)

Actions

Table overview

Data quality New

Table details

Advanced properties

Name
pentest_orders_xml

Description
-

Database
pentest_db

Classification
XML

Location
s3://kietduon-column-statistics-table/orders.xml

Connection
-

Deprecated
-

Last updated
October 25, 2023 at 19:14:47

Input format
-

Output format
-

Serde serialization lib
-

Schema

Partitions

Indexes

Column statistics - new

Column statistics (9)

Last updated (UTC)
November 6, 2023 at 21:50:40

Stop

View all runs

Generate statistics

Get an overview of the data profile. We estimate the approximate number of distinct values in a data set with 5% average relative error.

Find columns

Column name	Last updated (UTC)	Average length	Distinct values	Max length	Null values	Max value	Min value	True values	False values
o_clerk	October 25, 2023 at 19:14:	15.00	919	15	-	-	-	-	-
o_comment	October 25, 2023 at 19:14:	88.38	3156	124559	-	-	-	-	-
o_custkey	October 25, 2023 at 19:14:	-	919	-	-	1499	1	-	-
o_order-priority	October 25, 2023 at 19:14:	8.45	5	15	-	-	-	-	-
o_orderdate	October 25, 2023 at 19:14:	10.00	1790	10	-	-	-	-	-
o_orderkey	October 25, 2023 at 19:14:	-	3098	-	-	12451	1	-	-
o_orderstatus	October 25, 2023 at 19:14:	1.00	3	1	-	-	-	-	-
o_ship-priority	October 25, 2023 at 19:14:	-	1	-	-	-	-	-	-
o_totalprice	October 25, 2023 at 19:14:	-	3062	-	-	422359.65	974.04	-	-

Les statistiques suivantes sont disponibles :

- Nom de colonne : nom de colonne utilisé pour générer des statistiques
- Dernière mise à jour : date et heure de génération des statistiques
- Longueur moyenne : longueur moyenne des valeurs dans la colonne
- Valeurs distinctes : nombre total de valeurs distinctes dans la colonne. Nous estimons le nombre de valeurs distinctes dans une colonne avec une erreur relative de 5 %.
- Valeur maximale : la plus grande valeur de la colonne.
- Valeur minimale : la plus petite valeur de la colonne.
- Longueur maximale : longueur de la valeur la plus élevée dans la colonne.
- Valeurs nulles : nombre total de valeurs nulles dans la colonne.
- Valeurs réelles : nombre total de valeurs réelles dans la colonne.
- Valeurs fausses : nombre total de valeurs fausses dans la colonne.

Optimisation des performances des requêtes à l'aide des statistiques des colonnes

279

- NumFiles : nombre total de fichiers dans la table. Cette valeur est disponible sous l'onglet Propriétés avancées.

AWS CLI

L'exemple suivant montre comment récupérer les statistiques de colonne à l'aide de la AWS CLI.

```
aws glue get-column-statistics-for-table \
  --database-name database_name \
  --table-name table_name \
  --column-names <column_name>
```

Vous pouvez également consulter les statistiques des colonnes à l'aide de l'opération [GetColumnStatisticsForTable](#) API.

Affichage des exécutions de tâches de statistiques de colonne

Après avoir exécuté une tâche de statistiques de colonne, vous pouvez explorer les détails de l'exécution de la tâche pour une table à l'aide de AWS Glue la console AWS CLI ou à l'aide d'une [GetColumnStatisticsTaskRuns](#) opération.

Console

Pour afficher les détails de l'exécution de la tâche de statistiques de colonne

1. Sur AWS Glue la console, sélectionnez Tables sous Catalogue de données.
2. Sélectionnez une table avec des statistiques de colonne.
3. Sur la page Détails de la table, choisissez Statistiques de colonne.
4. Choisissez Afficher les exécutions.

Vous pouvez voir des informations sur toutes les exécutions associées à la table spécifiée.

The screenshot shows the AWS Glue console interface for viewing column statistics runs. The breadcrumb navigation is 'AWS Glue > Tables > path1 > All column statistics runs'. The main heading is 'All runs (1)' with a refresh icon and the text 'Last updated (UTC) November 16, 2023 at 00:21:44'. Below the heading is a search bar labeled 'Filter data'. The table below has columns: Run ID, Status, Start time (UTC), End time (UTC), Duration, Column selection, and Row sampling. One row is visible with Run ID 'f6a7b304-ad59-49d1-9...', Status 'Running', Start time 'November 16, 2023 at 00:...', End time '-', Duration '-', Column selection 'All columns', and Row sampling '100%'.

Run ID	Status	Start time (UTC)	End time (UTC)	Duration	Column selection	Row sampling
f6a7b304-ad59-49d1-9...	Running	November 16, 2023 at 00:...	-	-	All columns	100%

AWS CLI

Dans l'exemple suivant, remplacez les valeurs pour `DatabaseName` et `TableName` par le nom réel de la base de données et de la table.

```
aws glue get-column-statistics-task-runs --input-cli-json file://input.json
{
  "DatabaseName": "database_name",
  "TableName": "table_name"
}
```

Arrêt d'exécution de la tâche de statistiques de colonne

Vous pouvez arrêter une tâche de statistiques de colonne exécutée pour une table à l'aide de AWS Glue la console AWS CLI ou à l'aide d'une [StopColumnStatisticsTaskRun](#) opération.

Console

Pour arrêter l'exécution d'une tâche de statistiques de colonne

1. Sur AWS Glue la console, sélectionnez Tables sous Catalogue de données.
2. Sélectionnez la table dans laquelle l'exécution de la tâche de statistiques de colonne est en cours.
3. Sur la page Détails de la table, choisissez Statistiques de colonne.
4. Choisissez Arrêter.

Si vous arrêtez la tâche avant la fin de l'exécution, aucune statistique de colonne ne sera générée pour la table.

AWS CLI

Dans l'exemple suivant, remplacez les valeurs pour `DatabaseName` et `TableName` par le nom réel de la base de données et de la table.

```
aws glue stop-column-statistics-task-run --input-cli-json file://input.json
{
  "DatabaseName": "database_name",
  "TableName": "table_name"
}
```

```
}
```

Supprimer les statistiques de colonne

Vous pouvez supprimer les statistiques des colonnes à l'aide de [DeleteColumnStatisticsForTable](#) l'opération API ou AWS CLI. L'exemple suivant montre comment supprimer des statistiques de colonne à l'aide de AWS Command Line Interface (AWS CLI).

```
aws glue delete-column-statistics-for-table \  
  --database-name 'database_name' \  
  --table-name 'table_name' \  
  --column-name 'column_name'
```

Considérations et restrictions

Les considérations et limites suivantes s'appliquent à la génération de statistiques de colonne.

Considérations

- L'utilisation de l'échantillonnage pour générer des statistiques réduit le temps d'exécution, mais peut générer des statistiques inexactes.
- Le catalogue de données ne stocke pas les différentes versions des statistiques.
- Vous ne pouvez exécuter qu'une seule tâche de génération de statistiques à la fois par table.
- Si une table est chiffrée à l'aide d'une AWS KMS clé client enregistrée dans Data Catalog, AWS Glue utilise la même clé pour chiffrer les statistiques.

La tâche de statistiques de colonne prend en charge la génération de statistiques :

- Lorsque le rôle IAM dispose d'autorisations complètes sur les tables (IAM ou Lake Formation).
- Lorsque le rôle IAM dispose d'autorisations sur la table en utilisant le mode d'accès hybride de Lake Formation.

La tâche de statistiques de colonne ne prend pas en charge la génération de statistiques pour :

- Tables avec contrôle d'accès basé sur les cellules de Lake Formation

- Lacs de données transactionnels - Fondation Linux Delta Lake, Apache Hudi
- Tables dans des bases de données fédérées - Hive metastore, unités de partage des données d'Amazon Redshift
- Colonnes imbriquées, tableaux et types de données struct.
- Tableau partagé avec vous depuis un autre compte

Chiffrement de votre catalogue de données

Vous pouvez protéger vos métadonnées stockées dans l' AWS Glue Data Catalog at rest à l'aide de clés de chiffrement gérées par AWS Key Management Service (AWS KMS). Vous pouvez activer le chiffrement du catalogue de données pour le nouveau catalogue de données à l'aide des paramètres du catalogue de données. Vous pouvez activer ou désactiver le chiffrement pour le catalogue de données existant selon vos besoins. Lorsque cette option est activée, elle AWS Glue chiffre toutes les nouvelles métadonnées écrites dans le catalogue, tandis que les métadonnées existantes restent non chiffrées.

Pour obtenir des informations détaillées sur le chiffrement de votre catalogue de données, consultez [Chiffrement de votre catalogue de données](#).

Sécurisation de votre catalogue de données à l'aide de Lake Formation

AWS Lake Formation est un service qui facilite la configuration d'un lac de données sécurisé dans AWS. Il fournit un emplacement central pour créer et gérer en toute sécurité vos lacs de données en définissant des autorisations de contrôle d'accès précises. Lake Formation utilise le catalogue de données pour stocker et récupérer les métadonnées relatives à votre lac de données, telles que les définitions de tables, les informations de schéma et les paramètres de contrôle d'accès aux données.

Vous pouvez enregistrer l'emplacement de vos données Amazon S3 dans la table ou la base de données de métadonnées auprès de Lake Formation et l'utiliser pour définir des autorisations au niveau des métadonnées sur les ressources du catalogue de données. Vous pouvez également utiliser Lake Formation pour gérer les autorisations d'accès au stockage sur les données sous-jacentes stockées dans Amazon S3 pour le compte de moteurs d'analyse intégrés.

Pour plus d'informations, voir [Qu'est-ce que c'est AWS Lake Formation ?](#) .

Utilisation des AWS Glue Data Catalog vues dans AWS Glue

Vous pouvez créer et gérer des vues dans le AWS Glue Data Catalog, communément appelé AWS Glue Data Catalog vues. Ces vues sont utiles car elles prennent en charge plusieurs moteurs de requêtes SQL, ce qui vous permet d'accéder à la même vue sur différents AWS services Amazon Athena, tels que Amazon Redshift, et AWS Glue. Vous pouvez utiliser des vues basées sur Apache Iceberg, Apache Hudi et Delta Lake.

En créant une vue dans le catalogue de données, vous pouvez utiliser des autorisations de ressources et des contrôles d'accès basés sur des balises AWS Lake Formation pour autoriser l'accès à celui-ci. Avec cette méthode de contrôle d'accès, il n'est pas nécessaire de configurer un accès supplémentaire aux tables référencées lors de la création de la vue. Cette méthode d'octroi d'autorisations est appelée sémantique du définisseur, et ces vues sont appelées vues du définisseur. Pour plus d'informations sur le contrôle d'accès dans AWS Lake Formation, consultez la section [Octroi et révocation d'autorisations sur les ressources du catalogue de données](#) dans le guide du AWS Lake Formation développeur.

Les vues du catalogue de données sont utiles dans les cas d'utilisation suivants :

- **Contrôle d'accès granulaire** : vous pouvez créer une vue qui restreint l'accès aux données en fonction des autorisations dont l'utilisateur a besoin. Par exemple, vous pouvez utiliser les vues du catalogue de données pour empêcher les employés qui ne travaillent pas dans le service des ressources humaines de voir les informations personnelles identifiables (PII).
- **Définition complète de la vue** : en appliquant des filtres à votre vue dans le catalogue de données, vous vous assurez que les enregistrements de données disponibles dans la vue sont toujours complets.
- **Sécurité renforcée** — La définition de requête utilisée pour créer la vue doit être complète, afin que les vues du catalogue de données soient moins vulnérables aux commandes SQL provenant d'acteurs malveillants.
- **Partage de données simplifié** : partagez des données avec d'autres AWS comptes sans déplacer de données, grâce au partage de données entre comptes. AWS Lake Formation

Création d'un affichage du Catalogue de données

Vous pouvez créer des vues de catalogue de données à l'aide des scripts AWS Glue ETL AWS CLI et de Spark SQL. La syntaxe permettant de créer une vue du catalogue de données consiste à

spécifier le type de vue as `MULTI DIALECT` et le `SECURITY` prédicat as `DEFINER`, en indiquant une vue plus précise.

Exemple d'instruction SQL pour créer une vue du catalogue de données :

```
CREATE PROTECTED MULTI DIALECT VIEW database_name.catalog_view SECURITY DEFINER
AS SELECT order_date, sum(totalprice) AS price
FROM source_table
GROUP BY order_date;
```

Après avoir créé une vue du catalogue de données, vous pouvez utiliser un rôle IAM doté de l'autorisation AWS Lake Formation « `SELECT` » sur la vue pour l'interroger à partir de services tels que des tâches ETL ou des tâches Amazon Athena Amazon Redshift ETL. AWS Glue II n'est pas nécessaire d'autoriser l'accès aux tables sous-jacentes référencées dans la vue.

Pour plus d'informations sur la création et la configuration des vues du catalogue de données, voir [Création de vues du catalogue de AWS Glue données](#) dans le guide du AWS Lake Formation développeur.

Opérations d'affichage prises en charge

Les fragments de commande suivants vous montrent différentes manières d'utiliser les vues du catalogue de données :

CRÉER UNE VUE

Crée une vue du catalogue de données. Voici un exemple illustrant la création d'une vue à partir d'une table existante :

```
CREATE PROTECTED MULTI DIALECT VIEW catalog_view
SECURITY DEFINER AS SELECT * FROM my_catalog.my_database.source_table
```

MODIFIER LA VUE

Syntaxe disponible :

```
ALTER VIEW view_name [FORCE] ADD DIALECT AS query
ALTER VIEW view_name [FORCE] UPDATE DIALECT AS query
ALTER VIEW view_name DROP DIALECT
```

Vous pouvez utiliser `FORCE ADD DIALECT` cette option pour forcer la mise à jour du schéma et des sous-objets conformément au nouveau dialecte du moteur. Notez que cela peut entraîner des erreurs de requête si vous ne les utilisez pas également `FORCE` pour mettre à jour d'autres dialectes du moteur. Voici un exemple :

```
ALTER VIEW catalog_view FORCE ADD DIALECT AS
SELECT order_date, sum(totalprice) AS priceFROM source_tableGROUP BY orderdate;
```

Ce qui suit montre comment modifier une vue afin de mettre à jour le dialecte :

```
ALTER VIEW catalog_view UPDATE DIALECT AS
SELECT count(*) FROM my_catalog.my_database.source_table;
```

DÉCRIRE LA VUE

Syntaxe disponible pour décrire une vue :

`SHOW COLUMNS {FROM|IN} view_name [{FROM|IN} database_name]`— Si l'utilisateur dispose AWS Glue des AWS Lake Formation autorisations requises pour décrire la vue, il peut répertorier les colonnes. Voici quelques exemples de commandes permettant d'afficher des colonnes :

```
SHOW COLUMNS FROM my_database.source_table;
SHOW COLUMNS IN my_database.source_table;
```

`DESCRIBE view_name`— Si l'utilisateur dispose AWS Glue des AWS Lake Formation autorisations requises pour décrire la vue, il peut répertorier les colonnes de la vue ainsi que ses métadonnées.

SUPPRIMER LA VUE

Syntaxe disponible :

```
DROP VIEW [ IF EXISTS ] view_name
```

L'exemple suivant montre une `DROP` instruction qui teste si une vue existe avant de la supprimer :

```
DROP VIEW IF EXISTS catalog_view;
```


SHOW CREATE VIEW view_name— Affiche l'instruction SQL qui crée la vue spécifiée. Voici un exemple illustrant la création d'une vue de catalogue de données :

```
SHOW CREATE TABLE my_database.catalog_view;CREATE PROTECTED MULTI DIALECT VIEW
my_catalog.my_database.catalog_view (
  net_profit,
  customer_id,
  item_id,
  sold_date)
TBLPROPERTIES (
  'transient_lastDdlTime' = '1736267222')
SECURITY DEFINER AS SELECT * FROM
my_database.store_sales_partitioned_1f WHERE customer_id IN (SELECT customer_id from
source_table limit 10)
```

AFFICHER LES VUES

Répertoriez toutes les vues du catalogue, telles que les vues normales, les vues multidialectes (MDV) et les vues MDV sans le dialecte Spark. La syntaxe disponible est la suivante :

```
SHOW VIEWS [{ FROM | IN } database_name] [LIKE regex_pattern]:
```

Voici un exemple de commande permettant d'afficher les vues :

```
SHOW VIEWS IN marketing_analytics LIKE 'catalog_view*';
```

Pour plus d'informations sur la création et la configuration de vues de catalogue de données, voir [Création de vues de catalogue de AWS Glue données](#) dans le guide du AWS Lake Formation développeur.

Interrogation d'un affichage du Catalogue de données

Après avoir créé une vue du catalogue de données, vous pouvez interroger la vue. Le rôle IAM configuré dans vos AWS Glue tâches doit disposer de l'autorisation Lake Formation SELECT dans la vue du catalogue de données. Il n'est pas nécessaire d'autoriser l'accès aux tables sous-jacentes référencées dans la vue.

Une fois que tout est configuré, vous pouvez demander votre avis. Par exemple, vous pouvez exécuter la requête suivante pour accéder à une vue.

```
SELECT * from my_database.catalog_view LIMIT 10;
```

Limites

Tenez compte des limites suivantes lorsque vous utilisez les vues du catalogue de données.

- Vous ne pouvez créer des vues de catalogue de données qu'avec la AWS Glue version 5.0 et les versions ultérieures.
- Le définisseur de vues du catalogue de données doit avoir SELECT accès aux tables de base sous-jacentes auxquelles la vue accède. La création de la vue du catalogue de données échoue si des filtres Lake Formation sont imposés au rôle de définisseur d'une table de base spécifique.
- Les tables de base ne doivent pas être autorisées à entrer dans le lac de IAMAllowedPrincipals données AWS Lake Formation. Le cas échéant, l'erreur Multi Dialect views ne peut référencer que des tables sans les autorisations IAMAllowed Principaux se produit.
- L'emplacement Amazon S3 de la table doit être enregistré en tant qu'emplacement de lac de AWS Lake Formation données. Si la table n'est pas enregistrée, l'erreur Multi Dialect views may only reference AWS Lake Formation managed tables se produit. Pour plus d'informations sur la façon d'enregistrer des sites Amazon S3 dans AWS Lake Formation, consultez la section [Enregistrement d'un site Amazon S3](#) dans le guide du AWS Lake Formation développeur.
- Vous pouvez uniquement créer des vues PROTECTED de catalogue de données. UNPROTECTED les vues ne sont pas prises en charge.
- Vous ne pouvez pas référencer les tables d'un autre AWS compte dans une définition de vue du catalogue de données. Vous ne pouvez pas non plus référencer une table dans le même compte situé dans une région distincte.
- Pour partager des données entre un compte ou une région, la vue complète doit être partagée entre comptes et entre régions, à l'aide de liens vers des AWS Lake Formation ressources.
- Les fonctions définies par l'utilisateur (UDFs) ne sont pas prises en charge.
- Vous ne pouvez pas référencer d'autres vues dans les vues du catalogue de données.

Accès au catalogue de données

Vous pouvez utiliser le AWS Glue Data Catalog (catalogue de données) pour découvrir et comprendre vos données. Le catalogue de données fournit un moyen cohérent de gérer les

définitions de schéma, les types de données, les emplacements et les autres métadonnées. Vous pouvez accéder au catalogue de données en utilisant les méthodes suivantes :

- **AWS Glue console** — Vous pouvez accéder au catalogue de données et le gérer via la AWS Glue console, une interface utilisateur Web. La console vous permet de parcourir et de rechercher des bases de données, des tables et leurs métadonnées associées, ainsi que de créer, mettre à jour et supprimer des définitions de métadonnées.
- **AWS Glue crawler** — Les crawlers sont des programmes qui analysent automatiquement vos sources de données et alimentent le catalogue de données avec des métadonnées. Vous pouvez créer et exécuter des robots d'exploration pour découvrir et cataloguer des données provenant de diverses sources telles qu'Amazon S3, Amazon RDS, Amazon DynamoDB Amazon CloudWatch et de bases de données relationnelles compatibles JDBC telles que MySQL et PostgreSQL, ainsi que de plusieurs sources non sources telles que Snowflake et Google.AWS BigQuery
- **AWS Glue APIs** — Vous pouvez accéder au catalogue de données par programmation à l'aide du. AWS Glue APIs Ils vous APIs permettent d'interagir avec le catalogue de données par programmation, ce qui permet l'automatisation et l'intégration avec d'autres applications et services.
- **AWS Command Line Interface (AWS CLI)** — Vous pouvez utiliser le AWS CLI pour accéder au catalogue de données et le gérer à partir de la ligne de commande. La CLI fournit des commandes pour créer, mettre à jour et supprimer des définitions de métadonnées, ainsi que pour interroger et récupérer des informations de métadonnées.
- **Intégration avec d'autres AWS services** — Le catalogue de données s'intègre à divers autres AWS services, vous permettant d'accéder aux métadonnées stockées dans le catalogue et de les utiliser. Par exemple, vous pouvez utiliser Amazon Athena pour interroger des sources de données à l'aide des métadonnées du catalogue de données et pour gérer l'accès aux données et la gouvernance des ressources du catalogue de données. AWS Lake Formation

Rubriques

- [Connexion au catalogue de données à l'aide du point de terminaison AWS Glue Iceberg REST](#)
- [Connexion au catalogue de données à l'aide du point de terminaison de l'extension AWS Glue Iceberg REST](#)
- [AWS Glue Spécifications REST APIs pour Apache Iceberg](#)
- [Connexion au catalogue de données depuis une application Spark autonome](#)
- [Cartographie des données entre Amazon Redshift et Apache Iceberg](#)

- [Considérations et limites relatives à l'utilisation du catalogue REST d' AWS Glue Iceberg APIs](#)

Connexion au catalogue de données à l'aide du point de terminaison AWS Glue Iceberg REST

AWS Glue le point de terminaison Iceberg REST prend en charge les opérations d'API spécifiées dans la spécification REST d'Apache Iceberg. À l'aide d'un client REST Iceberg, vous pouvez connecter votre application exécutée sur un moteur d'analyse au catalogue REST hébergé dans le catalogue de données.

Le point de terminaison prend en charge les deux spécifications des tables Apache Iceberg : v1 et v2, la valeur par défaut étant v2. Lorsque vous utilisez la spécification de la table Iceberg v1, vous devez spécifier v1 dans l'appel d'API. À l'aide de l'opération API, vous pouvez accéder aux tables Iceberg stockées à la fois dans le stockage d'objets Amazon S3 et dans le stockage de tables Amazon S3.

Configuration du terminal

Vous pouvez accéder au catalogue REST d' AWS Glue Iceberg à l'aide du point de terminaison du service. Reportez-vous au [guide de référence des points AWS Glue de terminaison de service](#) pour le point de terminaison spécifique à la région. Par exemple, lorsque vous vous connectez AWS Glue à la région us-east-1, vous devez configurer la propriété URI du point de terminaison comme suit :

```
Endpoint : https://glue.us-east-1.amazonaws.com/iceberg
```

Propriétés de configuration supplémentaires — Lorsque vous utilisez le client Iceberg pour connecter un moteur d'analyse tel que Spark au point de terminaison du service, vous devez spécifier les propriétés de configuration d'application suivantes :

```
catalog_name = "mydatacatalog"
aws_account_id = "123456789012"
aws_region = "us-east-1"
spark = SparkSession.builder \
    ... \
    .config("spark.sql.defaultCatalog", catalog_name) \
    .config(f"spark.sql.catalog.{catalog_name}",
"org.apache.iceberg.spark.SparkCatalog") \
    .config(f"spark.sql.catalog.{catalog_name}.type", "rest") \
    .config(f"spark.sql.catalog.{catalog_name}.uri", "https://glue.
{aws_region}.amazonaws.com/iceberg") \
```

```
.config(f"spark.sql.catalog.{catalog_name}.warehouse", "{aws_account_id}") \
.config(f"spark.sql.catalog.{catalog_name}.rest.sigv4-enabled", "true") \
.config(f"spark.sql.catalog.{catalog_name}.rest.signing-name", "glue") \

.config("spark.sql.extensions", "org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions") \
.getOrCreate()
```

AWS Glue Les supports de point de terminaison Iceberg prennent en <https://glue.us-east-1.amazonaws.com/iceberg> charge le REST Iceberg suivant : APIs

- GetConfig
- ListNamespaces
- CreateNamespace
- LoadNamespaceMetadata
- UpdateNamespaceProperties
- DeleteNamespace
- ListTables
- CreateTable
- LoadTable
- TableExists
- UpdateTable
- DeleteTable

Paramètres du préfixe et du chemin du catalogue

Le catalogue REST d'Iceberg APIs comporte un préfixe de forme libre dans sa demande. URLs Par exemple, l'appel ListNamespaces d'API utilise le format d'GET/v1/{prefix}/namespacesURL. AWS Glue Le préfixe suit toujours la /catalogs/{catalog} structure pour garantir que le chemin REST aligne la hiérarchie des catalogues AWS Glue multiples. Le paramètre de {catalog} chemin peut être dérivé en fonction des règles suivantes :

Schéma d'accès	Catalogue Glue ID Style	Style de préfixe	Exemple d'ID de catalogue par défaut	Exemple de route REST
Accédez au catalogue par défaut dans le compte courant	non requis	:	ne s'applique pas	GET /v1/catalogs/:namespace
Accédez au catalogue par défaut dans un compte spécifique	accountID	accountID	111122223333	GET /v1/catalogs/111122223333/namespaces
Accédez à un catalogue imbriqué dans un compte courant	catalogue1/catalogue2	catalogue1/catalogue2	rmscatalog 1 : db1	GET /v1/catalogs/rmscatalog1:db1/namespaces
Accédez à un catalogue imbriqué dans un compte spécifique	Identifiant du compte : Catalog1/Catalog2	Identifiant du compte : Catalog1/Catalog2	123456789012/rms catalogue :db1	GET /v1/catalogs/123456789012:rmscatalog1:db1/namespaces

Le mappage de cet ID de catalogue vers le préfixe n'est requis que lorsque vous appelez directement le REST APIs. Lorsque vous utilisez le catalogue REST d' AWS Glue Iceberg APIs via un moteur, vous devez spécifier l'ID du AWS Glue catalogue dans le warehouse paramètre de l'API de votre catalogue REST Iceberg ou dans le `glue.id` paramètre de l'API de vos AWS Glue extensions. Par exemple, découvrez comment vous pouvez l'utiliser avec EMR Spark dans [Utiliser un cluster Iceberg avec Spark](#).

Paramètre de chemin d'espace de noms

Les espaces de noms du APIs chemin du catalogue REST d'Iceberg peuvent comporter plusieurs niveaux. Toutefois, il AWS Glue ne prend en charge que les espaces de noms à un seul niveau.

Pour accéder à un espace de noms dans une hiérarchie de catalogue à plusieurs niveaux, vous pouvez vous connecter à un catalogue à plusieurs niveaux situé au-dessus de l'espace de noms pour référencer l'espace de noms. Cela permet à tout moteur de requête prenant en charge la notation en 3 parties d'accéder `catalog.namespace.table` aux objets de la hiérarchie AWS Glue du catalogue à plusieurs niveaux sans problèmes de compatibilité par rapport à l'utilisation de l'espace de noms à plusieurs niveaux.

Connexion au catalogue de données à l'aide du point de terminaison de l'extension AWS Glue Iceberg REST

AWS Glue Le point de terminaison d'extension Iceberg REST fournit des fonctionnalités supplémentaires APIs, qui ne figurent pas dans la spécification REST d'Apache Iceberg, et fournit des fonctionnalités de planification des scans côté serveur. Ces informations supplémentaires APIs sont utilisées lorsque vous accédez aux tables stockées dans le stockage géré Amazon Redshift. Le point de terminaison est accessible depuis une application utilisant les AWS Glue Data Catalog extensions Apache Iceberg.

Configuration du point de terminaison : un catalogue contenant des tables dans le stockage géré Redshift est accessible via le point de terminaison de service. Reportez-vous au [guide de référence des points AWS Glue de terminaison de service](#) pour le point de terminaison spécifique à la région. Par exemple, lorsque vous vous connectez AWS Glue à la région us-east-1, vous devez configurer la propriété URI du point de terminaison comme suit :

Endpoint : `https://glue.us-east-1.amazonaws.com/extensions`

```
catalog_name = "myredshiftcatalog"
aws_account_id = "123456789012"
aws_region = "us-east-1"
spark = SparkSession.builder \
    .config("spark.sql.defaultCatalog", catalog_name) \
    .config(f"spark.sql.catalog.{catalog_name}",
"org.apache.iceberg.spark.SparkCatalog") \
    .config(f"spark.sql.catalog.{catalog_name}.type", "glue") \
    .config(f"spark.sql.catalog.{catalog_name}.glue.id",
"{123456789012}:redshiftnamespacecatalog/redshiftdb") \

    .config("spark.sql.extensions", "org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions") \
    .getOrCreate()
```

AWS Glue Spécifications REST APIs pour Apache Iceberg

Cette section contient les spécifications relatives au catalogue et à l' AWS Glue extension AWS Glue Iceberg REST APIs, ainsi que les APIs points à prendre en compte lors de leur utilisation.

Les demandes d'API adressées aux AWS Glue Data Catalog points de terminaison sont authentifiées à l'aide de AWS Signature Version 4 (SigV4). Consultez [AWS la section Signature version 4 pour les demandes d'API](#) pour en savoir plus sur AWS SigV4.

Lors de l'accès au point de terminaison du AWS Glue service et aux AWS Glue métadonnées, l'application assume un rôle IAM qui nécessite une action `glue:getCatalog` IAM.

L'accès au catalogue de données et à ses objets peut être géré à l'aide des autorisations du mode hybride IAM, Lake Formation ou Lake Formation.

Les catalogues fédérés du catalogue de données contiennent des emplacements de données enregistrés pour Lake Formation. Lake Formation utilise le catalogue de données pour fournir des autorisations de type base de données afin de gérer l'accès des utilisateurs aux objets du catalogue de données.

Vous pouvez utiliser les autorisations du mode hybride IAM ou Lake Formation pour gérer l'accès au catalogue de données par défaut et à ses objets. AWS Lake Formation

Pour créer, insérer ou supprimer des données dans les objets gérés par Lake Formation, vous devez configurer des autorisations spécifiques pour l'utilisateur ou le rôle IAM.

- `CREATE_CATALOG` — Nécessaire pour créer des catalogues
- `CREATE_DATABASE` — Nécessaire pour créer des bases de données
- `CREATE_TABLE` — Nécessaire pour créer des tables
- `DELETE` — Obligatoire pour supprimer des données d'une table
- `DESCRIBE` — Nécessaire pour lire les métadonnées
- `DROP` — Nécessaire pour supprimer/supprimer une table ou une base de données
- `INSERT` — Nécessaire lorsque le principal doit insérer des données dans une table
- `SELECT` — Nécessaire lorsque le principal doit sélectionner des données dans une table

Pour plus d'informations, consultez la [référence sur les autorisations de Lake Formation](#) dans le Guide du AWS Lake Formation développeur.

GetConfig

Informations générales

Nom de l'opération	GetConfig
Type	API du catalogue REST Iceberg
chemin REST	GET /iceberg/v1/config
Action IAM	colle : GetCatalog
Permissions de Lake Formation	Ne s'applique pas
CloudTrail event	colle : GetCatalog
Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L67

Considérations et restrictions

- Le paramètre de warehouse requête doit être défini sur l'ID du AWS Glue catalogue. S'il n'est pas défini, le catalogue racine du compte courant est utilisé pour renvoyer la réponse. Pour de plus amples informations, veuillez consulter [the section called "Paramètres du préfixe et du chemin du catalogue"](#).

GetCatalog

Informations générales

Nom de l'opération	GetCatalog
Type	AWS Glue API d'extension
chemin REST	GET/extensions/v1/catalogs/{catalogue}
Action IAM	colle : GetCatalog

Permissions de Lake Formation	DESCRIBE
CloudTrail event	colle : GetCatalog
Définition de l'API ouverte	https://github.com/aws-labs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml #L40

Considérations et restrictions

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.

ListNamespaces

Informations générales

Nom de l'opération	ListNamespaces
Type	API du catalogue REST Iceberg
chemin REST	GET/iceberg/v1/catalogs/{catalog}/namespaces
Action IAM	colle : GetDatabase
Permissions de Lake Formation	TOUT, DÉCRIRE, SÉLECTIONNER
CloudTrail event	colle : GetDatabase
Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml #L205

Considérations et restrictions

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Seuls les espaces de noms du niveau suivant sont affichés. Pour répertorier les espaces de noms à des niveaux plus profonds, spécifiez l'ID de catalogue imbriqué dans le paramètre de chemin du catalogue.

CreateNamespace

Informations générales

Nom de l'opération	CreateNamespace
Type	API du catalogue REST Iceberg
chemin REST	POST/iceberg/v1/catalogs/{catalog}/namespaces
Action IAM	colle : CreateDatabase
Permissions de Lake Formation	TOUT, DÉCRIRE, SÉLECTIONNER
CloudTrail event	colle : CreateDatabase
Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L256

Considérations et restrictions

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Seul un espace de noms à niveau unique peut être créé. Pour créer un espace de noms à plusieurs niveaux, vous devez créer chaque niveau de manière itérative et vous connecter au niveau à l'aide du paramètre de chemin du catalogue.

StartCreateNamespaceTransaction

Informations générales

Nom de l'opération	StartCreateNamespaceTransaction
Type	AWS Glue API d'extensions
chemin REST	POST/extensions/v1/catalogs/{catalog}/namespaces
Action IAM	colle : CreateDatabase

Permissions de Lake Formation	TOUT, DÉCRIRE, SÉLECTIONNER
CloudTrail event	colle : CreateDatabase
Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L256

Considérations et restrictions

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez créer qu'un espace de noms à un seul niveau. Pour créer des espaces de noms à plusieurs niveaux, vous devez créer chaque niveau de manière itérative et vous connecter au niveau à l'aide du paramètre de chemin du catalogue.
- L'API est asynchrone et renvoie un identifiant de transaction que vous pouvez utiliser pour le suivi à l'aide de l'appel d'CheckTransactionStatusAPI.
- Vous pouvez appeler cette API uniquement si l'appel GetCatalog d'API contient le paramètre `use-extensions=true` dans la réponse.

LoadNamespaceMetadata

Informations générales

Nom de l'opération	LoadNamespaceMetadata
Type	API du catalogue REST Iceberg
chemin REST	GET/iceberg/v1/catalogs/{catalog}/namespaces/{ns}
Action IAM	colle : GetDatabase
Permissions de Lake Formation	TOUT, DÉCRIRE, SÉLECTIONNER
CloudTrail event	colle : GetDatabase

Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L302
-----------------------------	---

Considérations et restrictions

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre de chemin REST. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.

UpdateNamespaceProperties

Informations générales

Nom de l'opération	UpdateNamespaceProperties
Type	API du catalogue REST Iceberg
chemin REST	POST /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/properties
Action IAM	colle : UpdateDatabase
Permissions de Lake Formation	TOUT, MODIFIER
CloudTrail event	colle : UpdateDatabase
Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L400

Considérations et restrictions

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.

- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre de chemin REST. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.

DeleteNamespace

Informations générales

Nom de l'opération	DeleteNamespace
Type	API du catalogue REST Iceberg
chemin REST	DELETE/iceberg/v1/catalogs/{catalog}/namespaces/{ns}
Action IAM	colle : DeleteDatabase
Permissions de Lake Formation	TOUT, DÉPOSER
CloudTrail event	colle : DeleteDatabase
Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L365

Considérations et restrictions

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.
- Si la base de données contient des objets, l'opération échouera.
- L'API est asynchrone et renvoie un identifiant de transaction que vous pouvez utiliser pour le suivi à l'aide de l'appel d'CheckTransactionStatusAPI.
- L'API ne peut être utilisée que si l'appel GetCatalog d'API l'indique use-extensions=true en réponse.

StartDeleteNamespaceTransaction

Informations générales

Nom de l'opération	StartDeleteNamespaceTransaction
Type	AWS Glue API d'extensions
chemin REST	DELETE /extensions/v1/catalogs/{catalog}/namespaces/{ns}
Action IAM	colle : DeleteDatabase
Permissions de Lake Formation	TOUT, DÉPOSER
CloudTrail event	colle : DeleteDatabase
Définition de l'API ouverte	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml #L85

Considérations et restrictions

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un seul espace de noms à niveau unique dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.
- Si la base de données contient des objets, l'opération échouera.
- L'API est asynchrone et renvoie un identifiant de transaction que vous pouvez utiliser pour le suivi à l'aide de l'appel d'CheckTransactionStatusAPI.
- L'API ne peut être utilisée que si l'appel GetCatalog d'API l'indique use-extensions=true en réponse.

ListTables

Informations générales

Nom de l'opération	ListTables
--------------------	------------

Type	API du catalogue REST Iceberg
chemin REST	GET /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables
Action IAM	colle : GetTables
Permissions de Lake Formation	TOUT, SÉLECTIONNER, DÉCRIRE
CloudTrail event	colle : GetTables
Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L463

Considérations et restrictions

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.
- Toutes les tables, y compris les tables autres que celles d'Iceberg, seront répertoriées. Pour déterminer si une table peut être chargée en tant que table Iceberg ou non, appelez LoadTable operation.

CreateTable

Informations générales

Nom de l'opération	CreateTable
Type	API du catalogue REST Iceberg
chemin REST	GET /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables
Action IAM	colle : CreateTable

Permissions de Lake Formation	TOUT, CREATE_TABLE
CloudTrail event	colle : CreateTable
Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L497

Considérations et restrictions

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.
- CreateTableavec mise en scène n'est pas prise en charge. Si le paramètre de stageCreate requête est spécifié, l'opération échouera. Cela signifie que les opérations similaires ne CREATE TABLE AS SELECT sont pas prises en charge et que vous pouvez utiliser une combinaison de CREATE TABLE et INSERT INTO comme solution de contournement.
- Le fonctionnement de l>CreateTableAPI ne prend pas en charge cette optionstate-create = TRUE.

StartCreateTableTransaction

Informations générales

Nom de l'opération	CreateTable
Type	AWS Glue API d'extensions
chemin REST	POST/extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables
Action IAM	colle : CreateTable
Permissions de Lake Formation	TOUT, CREATE_TABLE

CloudTrail event	colle : CreateTable
Définition de l'API ouverte	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml #L107

Considérations et restrictions

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre de chemin REST. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.
- CreateTableavec mise en scène n'est pas prise en charge. Si le paramètre de stageCreate requête est spécifié, l'opération échouera. Cela signifie que les opérations similaires ne CREATE TABLE AS SELECT sont pas prises en charge et que l'utilisateur doit utiliser une combinaison de CREATE TABLE et INSERT INTO pour contourner le problème.
- L'API est asynchrone et renvoie un identifiant de transaction que vous pouvez utiliser pour le suivi à l'aide de l'appel d'CheckTransactionStatusAPI.
- L'API ne peut être utilisée que si l'appel GetCatalog d'API l'indique use-extensions=true en réponse.

LoadTable

Informations générales

Nom de l'opération	LoadTable
Type	API du catalogue REST Iceberg
chemin REST	OBTENIR/iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Action IAM	Colle : GE TTable
Permissions de Lake Formation	TOUT, SÉLECTIONNER, DÉCRIRE
CloudTrail événement	colle : GetTable

Définition de l'API ouverte

[https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L616](https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L616)

Considérations

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un seul espace de noms de niveau dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.
- `CreateTableavec` mise en scène n'est pas prise en charge. Si le paramètre de `stageCreate` requête est spécifié, l'opération échouera. Cela signifie que les opérations similaires ne `CREATE TABLE AS SELECT` sont pas prises en charge et que l'utilisateur doit utiliser une combinaison de `CREATE TABLE` et `INSERT INTO` pour contourner le problème.
- L'API est asynchrone et renvoie un identifiant de transaction que vous pouvez utiliser pour le suivi à l'aide de l'appel d'`CheckTransactionStatusAPI`.
- L'API ne peut être utilisée que si l'appel `GetCatalog` d'API l'indique `use-extensions=true` en réponse.

ExtendedLoadTable

Informations générales

Nom de l'opération	LoadTable
Type	AWS Glue API d'extensions
chemin REST	GET /extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{tableau}
Action IAM	colle : GetTable
Permissions de Lake Formation	TOUT, SÉLECTIONNER, DÉCRIRE
CloudTrail événement	colle : GetTable

Définition de l'API ouverte

<https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L134>

Considérations

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.
- Seul all le mode est pris en charge pour le paramètre de requête des instantanés.
- Par rapport à LoadTable l'API, l'ExtendedLoadTableAPI se distingue des manières suivantes :
 - N'impose pas strictement que tous les champs soient disponibles.
 - fournit les paramètres supplémentaires suivants dans le champ de configuration de la réponse :

Paramètres supplémentaires

Clé de configuration	Description
aws. server-side-capabilities.scan-planning	Indique si le tableau peut être scanné à l'aide du PreparePlan tableau et PlanTable APIs.
aws. server-side-capabilities.data-commit	Indique si la table peut être validée à l'aide de la StartUpdateTable transaction.
aws.glue.staging.location	Utilisé pour la planification du scan côté serveur ou pour la validation des données, emplacement intermédiaire géré par le service qui peut être utilisé par le moteur pour écrire des fichiers de données temporaires
aws.glue.staging.access-key-id	Utilisé pour la planification du scan côté serveur ou pour la validation des données, il fait partie des informations d'AWS identification temporaires permettant d'accéder à l'emplacement intermédiaire géré par le service
aws.glue.staging.secret-access-key	Utilisé pour la planification du scan côté serveur ou pour la validation des données, il fait partie des informations

Clé de configuration	Description
	d' AWS identification temporaires permettant d'accéder à l'emplacement intermédiaire géré par le service.
jeton de session aws.glue.staging.session	Utilisé pour la planification du scan côté serveur ou pour la validation des données, il fait partie des informations d' AWS identification temporaires permettant d'accéder à l'emplacement intermédiaire géré par le service.
aws.glue.staging.expiration-ms	Utilisé pour la planification du scan côté serveur ou pour la validation des données, date d'expiration des informations d'identification pour accéder à l'emplacement intermédiaire géré par le service.
aws.glue.staging. data-transfer-role-arn	Utilisé pour la planification du scan côté serveur ou pour la validation des données, rôle IAM qui peut être assumé pour accéder à l'emplacement intermédiaire géré par le service.

PreplanTable

Informations générales

Nom de l'opération	PreplanTable
Type	AWS Glue API d'extensions
chemin REST	POST /extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}/preplan
Action IAM	colle : GetTable
Permissions de Lake Formation	TOUT, SÉLECTIONNER, DÉCRIRE
CloudTrail événement	colle : GetTable
Définition de l'API ouverte	https://github.com/aws-labs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml #L211

Considérations

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.
- L'appelant de cette API doit toujours déterminer s'il reste des résultats à récupérer en fonction du jeton de page. Une réponse avec un élément de page vide mais un jeton de pagination est possible si le côté serveur est toujours en cours de traitement mais n'est pas en mesure de produire un résultat dans le temps de réponse donné.
- Vous ne pouvez utiliser cette API que si la réponse de l'ExtendedLoadTableAPI contient `aws.server-side-capabilities.scan-planning=true`.

PlanTable

Informations générales

Nom de l'opération	PlanTable
Type	AWS Glue API d'extensions
chemin REST	POST /extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}/plan
Action IAM	colle : GetTable
Permissions de Lake Formation	TOUT, SÉLECTIONNER, DÉCRIRE
CloudTrail événement	colle : GetTable
Définition de l'API ouverte	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml #L243

Considérations

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.

- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.
- L'appelant de cette API doit toujours déterminer s'il reste des résultats à récupérer en fonction du jeton de page. Une réponse avec un élément de page vide mais un jeton de pagination est possible si le côté serveur est toujours en cours de traitement mais n'est pas en mesure de produire un résultat dans le temps de réponse donné.
- Vous ne pouvez utiliser cette API que si la réponse de l'ExtendedLoadTableAPI contient `aws.server-side-capabilities.scan-planning=true`.

TableExists

Informations générales

Nom de l'opération	TableExists
Type	API du catalogue REST Iceberg
chemin REST	HEAD/iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables/{tableau}
Action IAM	colle : GetTable
Permissions de Lake Formation	TOUT, SÉLECTIONNER, DÉCRIRE
CloudTrail événement	colle : GetTable
Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L833

Considérations

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.

UpdateTable

Informations générales

Nom de l'opération	UpdateTable
Type	API du catalogue REST Iceberg
chemin REST	POST /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables/{tableau}
Action IAM	colle : UpdateTable
Permissions de Lake Formation	TOUT, MODIFIER
CloudTrail événement	colle : UpdateTable
Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L677

Considérations

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.

StartUpdateTableTransaction

Informations générales

Nom de l'opération	StartUpdateTableTransaction
Type	AWS Glue API d'extension
chemin REST	POST/extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{tableau}
Action IAM	colle : UpdateTable

Permissions de Lake Formation	TOUT, MODIFIER
CloudTrail événement	colle : UpdateTable
Définition de l'API ouverte	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml #L154

Considérations

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.
- L'API est asynchrone et renvoie un identifiant de transaction que vous pouvez utiliser pour le suivi à l'aide de l'appel d'CheckTransactionStatusAPI.
- Une RenamTable opération peut également être effectuée par le biais de cette API. Dans ce cas, l'appelant doit également disposer de l'autorisation glue : CreateTable ou LakeFormation CREATE_TABLE pour renommer la table.
- Vous ne pouvez utiliser cette API que si la réponse de l'ExtendedLoadTableAPI contient `aws.server-side-capabilities.scan-planning=true`.

DeleteTable

Informations générales

Nom de l'opération	DeleteTable
Type	API du catalogue REST Iceberg
chemin REST	DELETE/iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables/{tableau}
Action IAM	colle : DeleteTable
Permissions de Lake Formation	TOUT, DÉPOSER

CloudTrail événement	colle : DeleteTable
Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L793

Considérations

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.
- `DeleteTable`Le fonctionnement de l'API prend en charge une option de purge. Lorsque la purge est définie sur `true`, les données de la table sont supprimées, sinon les données ne sont pas supprimées. Pour les tables dans Amazon S3, l'opération ne supprime pas les données des tables. L'opération échoue lorsque la table est stockée dans Amazon S3, et `purge = TRUE`, .

Pour les tables stockées dans le stockage géré Amazon Redshift, l'opération supprimera les données des tables, comme dans Amazon `DROP TABLE` Redshift. L'opération échoue lorsque la table est stockée dans Amazon Redshift et `purge = FALSE`

- `purgeRequest=true` n'est pas pris en charge.

StartDeleteTableTransaction

Informations générales

Nom de l'opération	StartDeleteTableTransaction
Type	AWS Glue API d'extensions
chemin REST	<code>DELETE /extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{tableau}</code>
Action IAM	colle : DeleteTable
Permissions de Lake Formation	TOUT, LAISSE TOMBER

CloudTrail événement	colle : DeleteTable
Définition de l'API ouverte	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api .yaml #L793

Considérations

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.
- Vous ne pouvez spécifier qu'un espace de noms à un seul niveau dans le paramètre REST Path. Pour plus d'informations, consultez la [the section called “Paramètre de chemin d'espace de noms”](#) section.
- `purgeRequest=false` n'est pas pris en charge.
- L'API est asynchrone et renvoie un identifiant de transaction qui peut être suivi.
`CheckTransactionStatus`

CheckTransactionStatus

Informations générales

Nom de l'opération	CheckTransactionStatus
Type	AWS Glue API d'extensions
chemin REST	POST/extensions/v1/transactions/status
Action IAM	La même autorisation que l'action qui initie la transaction
Permissions de Lake Formation	La même autorisation que l'action qui initie la transaction
Définition de l'API ouverte	https://github.com/aws-labs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml #L273

Considérations

- Le paramètre du chemin du catalogue doit suivre le style décrit dans la [the section called “Paramètres du préfixe et du chemin du catalogue”](#) section.

Connexion au catalogue de données depuis une application Spark autonome

Vous pouvez vous connecter au catalogue de données à partir d'une application support à l'aide d'un connecteur Apache Iceberg.

1. Créez un rôle IAM pour l'application Spark.
2. Connectez-vous au point de terminaison AWS Glue Iceberg Rest à l'aide du connecteur Iceberg.

```
# configure your application. Refer to https://docs.aws.amazon.com/cli/latest/
# userguide/cli-configure-envvars.html for best practices on configuring environment
# variables.
export AWS_ACCESS_KEY_ID=$(aws configure get appUser.aws_access_key_id)
export AWS_SECRET_ACCESS_KEY=$(aws configure get appUser.aws_secret_access_key)
export AWS_SESSION_TOKEN=$(aws configure get appUser.aws_secret_token)

export AWS_REGION=us-east-1
export REGION=us-east-1
export AWS_ACCOUNT_ID = {specify your aws account id here}

~/spark-3.5.3-bin-hadoop3/bin/spark-shell \
  --packages org.apache.iceberg:iceberg-spark-runtime-3.4_2.12:1.6.0 \
  --conf
"spark.sql.extensions=org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions"
\
  --conf "spark.sql.defaultCatalog=spark_catalog" \
  --conf "spark.sql.catalog.spark_catalog=org.apache.iceberg.spark.SparkCatalog" \
  --conf "spark.sql.catalog.spark_catalog.type=rest" \
  --conf "spark.sql.catalog.spark_catalog.uri=https://glue.us-east-1.amazonaws.com/
iceberg" \
  --conf "spark.sql.catalog.spark_catalog.warehouse = {AWS_ACCOUNT_ID}" \
  --conf "spark.sql.catalog.spark_catalog.rest.sigv4-enabled=true" \
  --conf "spark.sql.catalog.spark_catalog.rest.signing-name=glue" \
  --conf "spark.sql.catalog.spark_catalog.rest.signing-region=us-east-1" \
  --conf "spark.sql.catalog.spark_catalog.io-
impl=org.apache.iceberg.aws.s3.S3FileIO" \
  --conf
"spark.hadoop.fs.s3a.aws.credentials.provider=org.apache.hadoop.fs.s3a.SimpleAWSCredentialsProvider"
```

3. Interrogez les données dans le catalogue de données.

```
spark.sql("create database myicebergdb").show()
spark.sql("""CREATE TABLE myicebergdb.mytbl (name string) USING iceberg location
's3://bucket_name/mytbl'""")
spark.sql("insert into myicebergdb.mytbl values('demo') ").show()
```

Cartographie des données entre Amazon Redshift et Apache Iceberg

Redshift et Iceberg prennent en charge différents types de données. La matrice de compatibilité suivante décrit le support et les limites lors du mappage de données entre ces deux systèmes de données. Reportez-vous aux [types de données Amazon Redshift](#) et aux [spécifications des tables Apache Iceberg](#) pour plus de détails sur les types de données pris en charge dans les systèmes de données respectifs.

Type de données Redshift	Alias	Type de données Iceberg
SMALLINT	INT2	int
INTEGER	ENTIER, INT4	int
BIGINT	INT8	long
DECIMAL	NUMERIC	decimal
REAL	FLOAT4	float
REAL	FLOAT4	float
DOUBLE PRECISION	FLOAT8, FLOTTEUR	double
CHAR	CARACTÈRE, NCHAR	chaîne
VARCHAR	CARACTÈRE VARIABLE, NVARCHAR	chaîne
BPCHAR		chaîne
TEXT		chaîne

Type de données Redshift	Alias	Type de données Iceberg
DATE		date
TIME	HEURE SANS FUSEAU HORAIRE	time
TIME	HEURE AVEC FUSEAU HORAIRE	non pris en charge
TIMESTAMP	HORODATAGE SANS FUSEAU HORAIRE	TIMESTAMP
HORODATAGES	HORODATAGE AVEC FUSEAU HORAIRE	HORODATAGES
INTERVALLE D'UNE ANNÉE À L'AUTRE		Non pris en charge
INTERVALLE D'UN JOUR À L'AUTRE		Non pris en charge
BOOLEAN	BOOL	bool
HLLSKETCH		Non pris en charge
SUPER		Non pris en charge
VARBYTE	VARBINARY, BINARY VARYING	binary
GEOMETRY		Non pris en charge
GEOGRAPHY		Non pris en charge

Considérations et limites relatives à l'utilisation du catalogue REST d' AWS Glue Iceberg APIs

Voici les considérations et les limites liées à l'utilisation du comportement de fonctionnement du langage de définition de données de catalogue (DDL) d'Apache Iceberg REST.

Considérations

- **RenameTable** Comportement de l'API : l'opération `RenameTable` est prise en charge dans les tables d'Amazon Redshift, mais pas dans Amazon S3.
- Opérations DDL pour les espaces de noms et les tables dans Amazon Redshift — Les opérations de création, de mise à jour, de suppression pour les espaces de noms et les tables dans Amazon Redshift sont des opérations asynchrones car elles dépendent du moment où le groupe de travail géré par Amazon Redshift est disponible et du fait qu'une transaction DDL et DML conflictuelle est en cours et que l'opération doit attendre le verrouillage puis tenter de valider les modifications.

Limites

- Les vues APIs figurant dans la spécification REST d'Apache Iceberg ne sont pas prises en charge dans le catalogue REST d' AWS Glue Iceberg.

AWS Glue Bonnes pratiques en matière de catalogue de données

Cette section présente les meilleures pratiques pour gérer et utiliser efficacement le AWS Glue Data Catalog. Il met l'accent sur des pratiques telles que l'utilisation efficace des robots d'exploration, l'organisation des métadonnées, la sécurité, l'optimisation des performances, l'automatisation, la gouvernance des données et l'intégration avec d'autres AWS services.

- Utilisez les robots d'exploration de manière efficace : exécutez régulièrement des robots d'exploration pour tenir le catalogue de données en fonction up-to-date des modifications apportées à vos sources de données. Utilisez des analyses incrémentielles pour modifier fréquemment les sources de données afin d'améliorer les performances. Configurez les robots d'exploration pour ajouter automatiquement de nouvelles partitions ou mettre à jour les schémas lorsque des modifications sont détectées.
- Organiser et nommer les tables de métadonnées : établissez une convention de dénomination cohérente pour les bases de données et les tables du catalogue de données. Regroupez les sources de données associées dans des bases de données ou des dossiers logiques pour une

meilleure organisation. Utilisez des noms descriptifs qui indiquent le but et le contenu de chaque tableau.

- Gérez les schémas de manière efficace : tirez parti des fonctionnalités d'inférence de schémas des robots d' AWS Glue exploration. Passez en revue et mettez à jour les modifications du schéma avant de les appliquer afin d'éviter de perturber les applications en aval. Utilisez les fonctionnalités d'évolution du schéma pour gérer les modifications de schéma avec élégance.
- Sécuriser le catalogue de données : activez le chiffrement des données au repos et en transit pour le catalogue de données. Mettez en œuvre des politiques de contrôle d'accès précises pour restreindre l'accès aux données sensibles. Auditez et examinez régulièrement les autorisations et les journaux d'activité du catalogue de données.
- Intégration à d'autres AWS services Catalogue de données Utilisez le catalogue de données comme couche de métadonnées centralisée pour des services tels qu'Amazon Athena, Redshift Spectrum et. AWS Lake Formation Tirez parti des tâches AWS Glue ETL pour transformer et charger des données dans différents magasins de données tout en conservant les métadonnées dans le catalogue de données.
- Surveillez et optimisez les performances Catalogue de données Surveillez les performances des robots d'exploration et des tâches ETL à l'aide de Amazon CloudWatch métriques. Partitionnez les grands ensembles de données dans le catalogue de données pour améliorer les performances des requêtes. Mettez en œuvre des optimisations des performances pour les métadonnées fréquemment consultées.
- Restez à jour grâce à AWS Glue la documentation et au catalogue de données des meilleures pratiques Consultez régulièrement la AWS Glue documentation et les AWS Glue ressources pour connaître les dernières mises à jour, les meilleures pratiques et les recommandations. Participez à AWS Glue des webinaires, à des ateliers et à d'autres événements pour apprendre auprès d'experts et rester au courant des nouvelles fonctionnalités et capacités.

Surveillance des métriques d'utilisation du catalogue de données dans Amazon CloudWatch

AWS Glue Data Catalog les métriques d'utilisation sont désormais disponibles Amazon CloudWatch, ce qui simplifie la surveillance et la compréhension de l'utilisation des ressources dans votre catalogue de données. Vous avez désormais une visibilité immédiate sur l'utilisation des catalogues, des bases de données, des tables, des partitions et des connexions par l'API Glue Catalog, ce qui facilite le suivi de votre catalogue de données.

Vue d'ensemble des métriques du catalogue de données

AWS Glue Data Catalog publie automatiquement les statistiques d'utilisation sur Amazon CloudWatch. Grâce à l'intégration CloudWatch des métriques, vous pouvez suivre les indicateurs de performance critiques à chaque minute, notamment :

- Demandes de table
- Index de partition créés
- Connexions mises à jour
- Statistiques mises à jour


Ces indicateurs vous aident à identifier les goulots d'étranglement, à détecter les anomalies et à prendre des décisions basées sur les données afin d'améliorer la fiabilité globale du catalogue de données. Vous pouvez également configurer des CloudWatch alarmes pour recevoir des notifications lorsque les mesures dépassent les seuils spécifiés, ce qui permet une gestion proactive de votre déploiement.

Ajouter des métriques à votre CloudWatch tableau de bord

Vous pouvez créer des tableaux de bord personnalisés pour surveiller vos AWS Glue Data Catalog ressources et configurer des alarmes pour être averti de toute activité inhabituelle.

Vous pouvez ajouter les métriques du catalogue de données à votre CloudWatch tableau de bord en suivant ces étapes :

1. Ouvrez la CloudWatch console à l'adresse <https://console.aws.amazon.com/cloudwatch/>.
2. Dans le panneau de navigation, sélectionnez Métriques.
3. Choisissez Toutes les mesures.
4. Choisissez Utilisation>Par ressource AWS .
5. Filtrez par Glue pour voir les statistiques disponibles.
6. Sélectionnez les indicateurs que vous souhaitez ajouter à votre tableau de bord.
7. Ajoutez des métriques pour les catalogues, les bases de données, les tables, les partitions et les connexions à votre CloudWatch graphique.



Vous pouvez configurer des alarmes personnalisées qui se déclenchent automatiquement lorsque l'utilisation de l'API dépasse les seuils définis afin d'identifier les anomalies dans l'utilisation de votre catalogue de données.

Pour obtenir des instructions détaillées sur la configuration des alarmes, voir [Création d'une CloudWatch alarme Metrics Insights](#).

AWS Glue Registre de schémas

Note

AWS Glue Le registre des schémas n'est pas pris en charge dans les régions suivantes de la AWS Glue console : Asie-Pacifique (Jakarta), Europe (Zurich) et Moyen-Orient (Émirats arabes unis).

Le AWS Glue Le registre des schémas vous permet de découvrir, de contrôler et de faire évoluer de manière centralisée les schémas de flux de données. Un schéma définit la structure et le format d'un enregistrement de données. Avec AWS Glue Registre de schémas, vous pouvez gérer et appliquer des schémas sur vos applications de streaming de données à l'aide d'intégrations pratiques avec Apache Kafka [Amazon Managed Streaming for Apache Kafka](#), [Amazon Kinesis Data Streams](#), [Amazon Managed Service pour Apache Flink](#) et. [AWS Lambda](#)

Le registre des schémas prend en charge le format de données AVRO (v1.11.4), le format de données JSON avec le format de [schéma JSON pour le schéma \(spécifications Draft-04, Draft-06 et Draft-07\) avec validation du schéma JSON à l'aide de la bibliothèque Everit, les versions proto2 et proto3 de Protocol Buffers \(Protobuf\) sans support pour ou, et le support du langage Java, avec d'autres formats](#) de données et langages à venir. extensions groups Les fonctionnalités prises en charge incluent la compatibilité, l'approvisionnement en schémas via des métadonnées, l'enregistrement automatique des schémas, la compatibilité IAM et la compression ZLIB en option pour réduire le stockage et le transfert de données. Le registre Schema est sans serveur et peut être utilisé gratuitement.

L'utilisation d'un schéma comme contrat de format de données entre applications producteur et consommateur conduit à une meilleure gouvernance des données, à une meilleure qualité des données, et permet aux applications consommateur de données d'être résilientes face aux changements compatibles en amont.

Le registre des schémas permet à des systèmes disparates de partager un schéma pour la sérialisation et la désérialisation. Par exemple, supposons que vous ayez un producteur et un consommateur de données. Le producteur connaît le schéma lorsqu'il publie les données. Le registre de schémas fournit un sérialiseur et un désérialiseur pour certains systèmes tels qu'Amazon MSK ou Apache Kafka.

Pour de plus amples informations, veuillez consulter [Fonctionnement du registre des schémas](#).

Rubriques

- [Schémas](#)
- [Registres](#)
- [Gestion des versions et compatibilité des schémas](#)
- [Bibliothèques Serde en open source](#)
- [Quotas du registre des schémas](#)
- [Fonctionnement du registre des schémas](#)
- [Commencer à utiliser le registre des schémas](#)
- [Intégration à AWS Glue Registre de schémas](#)
- [Migration depuis un registre de schémas tiers vers AWS Glue Registre de schémas](#)

Schémas

Un schéma définit la structure et le format d'un enregistrement de données. Un schéma est une spécification versionnée pour la publication, la consommation ou le stockage des données fiables.

Dans cet exemple de schéma pour Avro, le format et la structure sont définis par la disposition et les noms de champs, tandis que le format des noms de champs est défini par les types de données (par exemple, `string`, `int`).

```
{
  "type": "record",
  "namespace": "ABC_Organization",
  "name": "Employee",
  "fields": [
    {
      "name": "Name",
      "type": "string"
    },
    {
      "name": "Age",
      "type": "int"
    },
    {
      "name": "address",
      "type": {
        "type": "record",
        "name": "addressRecord",
```

```
    "fields": [
      {
        "name": "street",
        "type": "string"
      },
      {
        "name": "zipcode",
        "type": "int"
      }
    ]
  }
}
```

Dans cet exemple de schéma JSON draft-07 pour JSON, le format est défini par l'organisation du schéma [JSON](#).

```
{
  "$id": "https://example.com/person.schema.json",
  "$schema": "http://json-schema.org/draft-07/schema#",
  "title": "Person",
  "type": "object",
  "properties": {
    "firstName": {
      "type": "string",
      "description": "The person's first name."
    },
    "lastName": {
      "type": "string",
      "description": "The person's last name."
    },
    "age": {
      "description": "Age in years which must be equal to or greater than zero.",
      "type": "integer",
      "minimum": 0
    }
  }
}
```

Dans cet exemple pour Protobuf, le format est défini par la [version 2 du langage Protocol Buffers \(proto2\)](#).

```
syntax = "proto2";

package tutorial;

option java_multiple_files = true;
option java_package = "com.example.tutorial.protos";
option java_outer_classname = "AddressBookProtos";

message Person {
    optional string name = 1;
    optional int32 id = 2;
    optional string email = 3;

    enum PhoneType {
        MOBILE = 0;
        HOME = 1;
        WORK = 2;
    }

    message PhoneNumber {
        optional string number = 1;
        optional PhoneType type = 2 [default = HOME];
    }

    repeated PhoneNumber phones = 4;
}

message AddressBook {
    repeated Person people = 1;
}
```

Registres

Un registre est un conteneur logique de schémas. Les registres vous permettent d'organiser vos schémas, ainsi que de gérer le contrôle des accès pour vos applications. Un registre possède un Amazon Resource Name (ARN) qui vous permet d'organiser et de définir différentes autorisations d'accès aux opérations de schéma dans le registre.

Vous pouvez utiliser le registre par défaut ou créer autant de registres que nécessaire.

AWS Glue Hiérarchie du registre des schémas

- RegistryName: [chaîne]
 - RegistryArn: [AWS ARN]
 - CreatedTime: [horodatage]
 - UpdatedTime: [horodatage]
- SchemaName: [chaîne]
 - SchemaArn: [AWS ARN]
 - DataFormat: [Avro, Json ou Protobuf]
 - Compatibility : [par ex., BACKWARD, BACKWARD_ALL, FORWARD, FORWARD_ALL, FULL, FULL_ALL, NONE, DISABLED]
 - Status : [par ex., PENDING, AVAILABLE, DELETING]
 - SchemaCheckpoint: [entier]
 - CreatedTime: [horodatage]
 - UpdatedTime: [horodatage]
- SchemaVersion: [chaîne]
 - SchemaVersionNumber: [entier]
 - Status : [par ex., PENDING, AVAILABLE, DELETING, FAILURE]
 - SchemaDefinition: [chaîne, valeur : JSON]
 - CreatedTime: [horodatage]
- SchemaVersionMetadata: [liste]
 - MetadataKey: [chaîne]
 - MetadataInfo
 - MetadataValue: [chaîne]
 - CreatedTime: [horodatage]

Gestion des versions et compatibilité des schémas

Chaque schéma peut avoir plusieurs versions. La gestion des versions est régie par une règle de compatibilité appliquée à un schéma. Les demandes d'enregistrement de nouvelles versions de

schéma sont vérifiées par rapport à cette règle par le registre de schémas avant qu'elles ne puissent aboutir.

Une version de schéma qui est marquée comme point de contrôle est utilisée pour déterminer la compatibilité de l'enregistrement de nouvelles versions d'un schéma. Lorsqu'un schéma est créé pour la première fois, le point de contrôle par défaut sera la première version. Au fur et à mesure que le schéma évolue avec d'autres versions, vous pouvez utiliser la CLI/le SDK pour modifier le point de contrôle en version d'un schéma à l'aide de l'API `UpdateSchema` qui adhère à un ensemble de contraintes. Dans la console, la modification de la définition du schéma ou du mode de compatibilité modifiera le point de contrôle vers la dernière version par défaut.

Les modes de compatibilité vous permettent de contrôler la manière dont les schémas peuvent ou ne peuvent pas évoluer au fil du temps. Ces modes constituent le contrat entre les applications produisant et consommant des données. Lorsqu'une nouvelle version d'un schéma est envoyée au registre, la règle de compatibilité appliquée au nom du schéma est utilisée pour déterminer si la nouvelle version peut être acceptée. Il existe huit modes de compatibilité : `NONE`, `DISABLED`, `BACKWARD`, `BACKWARD_ALL`, `FORWARD_ALL`, `FULL`, `FULL_ALL`.

Au format de données Avro, les champs peuvent être facultatifs ou obligatoires. Un champ facultatif est celui dans lequel le champ `Type` inclut une valeur `null`. Les champs obligatoires n'ont pas de valeur nulle comme `Type`.

Dans le format de données Protobuf, les champs peuvent être facultatifs (y compris ceux répétés) ou obligatoires dans la syntaxe `proto2`, tandis que tous les champs sont facultatifs (y compris ceux répétés) dans la syntaxe `proto3`. Toutes les règles de compatibilité sont déterminées en fonction de la compréhension des spécifications de Protocol Buffers, ainsi que des directives de la [Documentation Protocol Buffers de Google](#).

- **NONE (AUCUN)** : aucun mode de compatibilité ne s'applique. Vous pouvez utiliser ce choix dans les scénarios de développement ou si vous ne connaissez pas les modes de compatibilité que vous souhaitez appliquer aux schémas. Toute nouvelle version ajoutée sera acceptée sans faire l'objet d'un contrôle de compatibilité.
- **DISABLED (DÉSACTIVÉ)** : ce choix de compatibilité empêche la gestion des versions pour un schéma particulier. Aucune nouvelle version ne peut être ajoutée.
- **BACKWARD (DESCENDANT)** : ce choix de compatibilité est recommandé, car il permet aux applications consommateur de lire à la fois la version actuelle et la version précédente du schéma. Vous pouvez utiliser ce choix pour vérifier la compatibilité par rapport à la version précédente du schéma lorsque vous supprimez des champs ou ajoutez des champs facultatifs. Un cas d'utilisation

typique pour BACKWARD (DESCENDANT) est lorsque votre application a été créée pour le schéma le plus récent.

AVRO

Par exemple, supposons que vous avez un schéma défini par le prénom (obligatoire), le nom (obligatoire), l'adresse électronique (obligatoire) et le numéro de téléphone (facultatif).

Si votre prochaine version de schéma supprime le champ d'adresse électronique requis, l'enregistrement s'effectue correctement. La compatibilité BACKWARD (DESCENDANT) exige que les applications consommateur soient en mesure de lire la version actuelle et précédente du schéma. Vos applications consommateur seront en mesure de lire le nouveau schéma, car le champ d'adresse électronique supplémentaire des anciens messages est ignoré.

Si vous avez proposé une nouvelle version de schéma qui ajoute un champ obligatoire, par exemple, le code postal, elle ne s'enregistrerait pas avec la compatibilité BACKWARD (DESCENDANT). Vos applications consommateur sur la nouvelle version ne seraient pas en mesure de lire les anciens messages avant la modification du schéma, car elles ne disposent pas du champ de code postal requis. Toutefois, si le champ de code postal a été défini comme facultatif dans le nouveau schéma, la version proposée s'enregistrerait avec succès, car les applications consommateur peuvent lire l'ancien schéma sans le champ de code postal facultatif.

JSON

Par exemple, supposons que vous avez une version de schéma définie par le prénom (facultatif), le nom de famille (facultatif), l'adresse électronique (facultatif) et le numéro de téléphone (facultatif).

Si votre prochaine version de schéma ajoute la propriété de numéro de téléphone facultative, elle s'enregistrera avec succès tant que la version de schéma d'origine n'autorise aucune propriété supplémentaire en définissant le champ `additionalProperties` sur `false`. La compatibilité BACKWARD (DESCENDANT) exige que les applications consommateur soient en mesure de lire la version actuelle et précédente du schéma. Vos applications consommateur seront en mesure de lire les données produites avec le schéma d'origine où la propriété de numéro de téléphone n'existe pas.

Si vous avez une proposition de nouvelle version de schéma qui ajoute la propriété de numéro de téléphone facultative, elle ne s'enregistrerait pas correctement avec la compatibilité BACKWARD (DESCENDANT) lorsque la version de schéma d'origine définit le champ `additionalProperties` sur `true`, à savoir autoriser toute propriété supplémentaire. Vos

applications consommateur sur la nouvelle version ne seraient pas en mesure de lire les anciens messages avant le changement de schéma, car elles ne peuvent pas lire les données avec la propriété de numéro de téléphone dans un type différent, par exemple une chaîne au lieu d'un numéro.

PROTOBUF

Par exemple, imaginez que vous avez une version de schéma définie par un message `Person` avec `first name` (obligatoire), `last name` (obligatoire), `email` (obligatoire) et le champ `phone number` (facultatifs) sous la syntaxe `proto2`.

Similaire aux scénarios AVRO, si la version de schéma suivante supprime le champ requis `email`, l'enregistrement s'effectue correctement. La compatibilité BACKWARD (DESCENDANT) exige que les applications consommateur soient en mesure de lire la version actuelle et précédente du schéma. Les consommateurs seront en mesure de lire le nouveau schéma, car le champ supplémentaire `email` des anciens messages est ignoré.

Si vous avez proposé une nouvelle version de schéma qui ajoute un champ obligatoire, par exemple, `zip code`, l'enregistrement ne s'effectue pas correctement avec la compatibilité DESCENDANTE. Les consommateurs sur la nouvelle version ne seraient pas en mesure de lire les anciens messages avant la modification du schéma, car ils ne disposent pas du champ requis `zip code`. Toutefois, si le champ `zip code` a été défini comme facultatif dans le nouveau schéma, l'enregistrement de la version proposée s'effectue correctement, car les consommateurs peuvent lire l'ancien schéma sans le champ facultatif `zip code`.

Dans le cas d'un cas d'utilisation de gRPC, l'ajout d'un nouveau service RPC ou d'une nouvelle méthode RPC est une modification de compatibilité descendante. Par exemple, imaginez que vous avez une version de schéma définie par un service RPC `MyService` avec deux méthodes RPC, `Foo` et `Bar`.

Si la version de schéma suivante ajoute une nouvelle méthode RPC appelée `Baz`, l'enregistrement s'effectue correctement. Les consommateurs seront en mesure de lire les données produites avec le schéma d'origine, en fonction de la compatibilité DESCENDANTE, car la nouvelle méthode RPC ajoutée `Baz` est facultative.

Si vous avez proposé une nouvelle version de schéma qui supprime la méthode RPC existante `Foo`, l'enregistrement ne s'effectue pas correctement avec la compatibilité DESCENDANTE. Les consommateurs sur la nouvelle version ne seraient pas en mesure de lire les anciens messages

avant la modification du schéma, car ils ne peuvent pas comprendre et lire les données avec la méthode RPC inexistante Foo dans une application gRPC.

- **BACKWARD_ALL (DESCENDANT_TOUT)** : ce choix de compatibilité permet aux applications consommateur de lire à la fois la version actuelle et toutes les versions antérieures du schéma. Vous pouvez utiliser ce choix pour vérifier la compatibilité avec toutes les versions de schéma précédentes lorsque vous supprimez des champs ou ajoutez des champs facultatifs.
- **FORWARD (ASCENDANT)** : ce choix de compatibilité permet aux applications consommateur de lire à la fois la version actuelle et les versions suivantes du schéma, mais pas nécessairement les versions ultérieures. Vous pouvez utiliser ce choix pour vérifier la compatibilité avec la dernière version de schéma lorsque vous ajoutez des champs ou supprimez des champs facultatifs. Un cas d'utilisation typique pour FORWARD (ASCENDANT) est lorsque votre application a été créée pour un schéma précédent et devrait être capable de traiter un schéma plus récent.

AVRO

Par exemple, supposons que vous avez une version de schéma définie par le prénom (obligatoire), le nom (obligatoire) et l'adresse électronique (facultatif).

Si vous disposez d'une nouvelle version de schéma qui ajoute un champ obligatoire ; par exemple, un numéro de téléphone, l'enregistrement s'effectue correctement. La compatibilité FORWARD (ASCENDANT) exige que les applications consommateur puissent lire les données produites avec le nouveau schéma à l'aide de la version précédente.

Si vous avez une version de schéma proposée qui supprime le champ de prénom obligatoire, elle ne s'enregistrerait pas avec la compatibilité FORWARD (ASCENDANT). Vos applications consommateur sur la version précédente ne seraient pas en mesure de lire les schémas proposés, car elles ne disposent pas du champ de prénom obligatoire. Toutefois, si le champ de prénom était initialement facultatif, le nouveau schéma proposé s'enregistrerait correctement, car les applications consommateur peuvent lire des données basées sur le nouveau schéma qui ne dispose pas du champ de prénom facultatif.

JSON

Par exemple, supposons que vous avez une version de schéma définie par le prénom (facultatif), le nom de famille (facultatif), l'adresse électronique (facultatif) et le numéro de téléphone (facultatif).

Si vous disposez d'une nouvelle version de schéma qui supprime la propriété de numéro de téléphone facultative, elle s'enregistrera avec succès tant que la nouvelle version de schéma

n'autorise aucune propriété supplémentaire en définissant le champ `additionalProperties` sur `false`. La compatibilité FORWARD (ASCENDANT) exige que les applications consommateur puissent lire les données produites avec le nouveau schéma à l'aide de la version précédente.

Si vous avez une proposition de version de schéma qui supprime la propriété de numéro de téléphone facultative, elle ne s'enregistrerait pas correctement avec la compatibilité FORWARD (ASCENDANT) lorsque la nouvelle version de schéma définit le champ `additionalProperties` sur `true`, à savoir autoriser toute propriété supplémentaire. Vos applications consommateur sur la version précédente ne seraient pas en mesure de lire les schémas proposés, car elles pourraient avoir la propriété de numéro de téléphone dans un type différent, par exemple une chaîne au lieu d'un numéro.

PROTOBUF

Par exemple, imaginez que vous avez une version de schéma définie par un message `Person` avec des champs `first name` (obligatoire), `last name` (obligatoire), `email` (facultatif) sous la syntaxe `proto2`.

Similaire aux scénarios AVRO, si vous disposez d'une nouvelle version de schéma qui ajoute un champ obligatoire ; par exemple `phone number`, l'enregistrement s'effectue correctement. La compatibilité FORWARD (ASCENDANT) exige que les applications consommateur puissent lire les données produites avec le nouveau schéma à l'aide de la version précédente.

Si vous avez une version de schéma proposée qui supprime le champ obligatoire `first name`, l'enregistrement ne s'effectue pas correctement avec la compatibilité ASCENDANTE. Les consommateurs sur la version précédente ne seraient pas en mesure de lire les schémas proposés, car le champ obligatoire `first name` est absent. Toutefois, si le champ `first name` était initialement facultatif, l'enregistrement du nouveau schéma proposé s'effectue correctement, car les consommateurs peuvent lire des données basées sur le nouveau schéma où le champ facultatif `first name` est absent.

Dans le cas d'un cas d'utilisation de gRPC, la suppression d'un service RPC ou d'une méthode RPC est une modification de compatibilité ascendante. Par exemple, imaginez que vous avez une version de schéma définie par un service RPC `MyService` avec deux méthodes RPC, `Foo` et `Bar`.

Si la version de schéma suivante supprime la méthode RPC existante nommée `Foo`, l'enregistrement s'effectue correctement en fonction de la compatibilité ASCENDANTE, car les consommateurs peuvent lire les données produites avec le nouveau schéma à l'aide de la version précédente. Si vous avez une nouvelle version de schéma proposée qui ajoute une méthode

RPC Baz, l'enregistrement ne s'effectue pas correctement avec la compatibilité ASCENDANTE. Les consommateurs sur la version précédente ne seraient pas en mesure de lire les schémas proposés, car ils ne disposent pas de la méthode RPC Baz.

- **FORWARD_ALL (ASCENDANT_TOUT)** : ce choix de compatibilité permet aux applications consommateur de lire les données écrites par les applications producteur de tout nouveau schéma enregistré. Vous pouvez utiliser ce choix lorsque vous devez ajouter des champs ou supprimer des champs facultatifs, et vérifier la compatibilité avec à toutes les versions de schéma précédentes.
- **FULL (COMPLET)** : ce choix de compatibilité permet aux applications consommateur de lire les données écrites par les applications producteur en utilisant la version précédente ou suivante du schéma, mais pas les versions antérieures ou ultérieures. Vous pouvez utiliser ce choix pour vérifier la compatibilité avec la dernière version de schéma lorsque vous ajoutez ou supprimez des champs facultatifs.
- **FULL_ALL (COMPLET_TOUT)** : ce choix de compatibilité permet aux applications consommateur de lire les données écrites par les applications producteur utilisant toutes les versions de schéma précédentes. Vous pouvez utiliser ce choix pour vérifier la compatibilité par rapport à toutes les versions de schéma précédentes lorsque vous ajoutez ou supprimez des champs facultatifs.

Bibliothèques Serde en open source

AWS fournit des bibliothèques Serde open source comme framework pour la sérialisation et la désérialisation des données. La conception open source de ces bibliothèques permet aux applications et aux cadres open source communs de prendre en charge ces bibliothèques dans leurs projets.

Pour plus de détails sur le fonctionnement des bibliothèques Serde, veuillez consulter [Fonctionnement du registre des schémas](#).

Quotas du registre des schémas

Les quotas, également appelés limites dans AWS, sont les valeurs maximales pour les ressources, les actions et les éléments de votre AWS compte. Les limites souples suivantes s'appliquent au registre des schémas dans AWS Glue.

Paires clé-valeur des métadonnées de version de schéma

Vous pouvez avoir jusqu'à 10 paires clé-valeur SchemaVersion par région. AWS

Vous pouvez afficher ou définir les paires de métadonnées clé-valeur à l'aide du [QuerySchemaVersionMetadata action \(Python : `query\_schema\_version\_metadata`\)](#) ou. [PutSchemaVersionMetadata action \(Python : `put\_schema\_version\_metadata`\)](#) APIs

Les limites suivantes sont strictes pour le registre de schémas dans AWS Glue.

Registres

Vous pouvez avoir jusqu'à 100 registres par AWS région pour ce compte.

SchemaVersion

Vous pouvez avoir jusqu'à 10 000 versions de schéma par AWS région pour ce compte.

Chaque nouveau schéma crée une nouvelle version du schéma. Vous pouvez donc théoriquement avoir jusqu'à 10 000 schémas par compte et par région, si chaque schéma ne possède qu'une seule version.

Charges utiles de schéma

Il existe une limite de taille de 170 Ko pour les charges utiles de schéma.

Fonctionnement du registre des schémas

Cette section décrit le fonctionnement des processus de sérialisation et de désérialisation dans le registre des schémas.

1. Enregistrer un schéma : si le schéma n'existe pas encore dans le registre, le schéma peut être enregistré avec un nom de schéma égal au nom de la destination (par exemple, `test_topic`, `test_stream`, `prod_firehose`) ou le producteur peut fournir un nom personnalisé pour le schéma. Les producteurs peuvent également ajouter des paires clé-valeur au schéma sous forme de métadonnées, telles que `source : MSK_Kafka_Topic_A`, ou appliquer des balises aux schémas lors de la création du schéma. AWS Une fois qu'un schéma est enregistré, le registre de schémas renvoie l'ID de version de schéma au sérialiseur. Si le schéma existe, mais que le sérialiseur utilise une nouvelle version qui n'existe pas, le registre de schémas vérifie que le schéma fait référence à une règle de compatibilité pour s'assurer que la nouvelle version est compatible avant de l'enregistrer en tant que nouvelle version.

Il existe deux méthodes d'enregistrement d'un schéma : l'enregistrement manuel et l'enregistrement automatique. Vous pouvez enregistrer un schéma manuellement via AWS Glue console ou CLI/SDK.

Lorsque l'enregistrement automatique est activé dans les paramètres du sérialiseur, l'enregistrement automatique du schéma est effectué. Si la valeur `REGISTRY_NAME` n'est pas fournie dans les configurations du producteur, l'enregistrement automatique enregistrera alors la nouvelle version du schéma sous le registre par défaut (`default-registry`). Voir [Installation de SerDe bibliothèques](#) pour plus d'informations sur la spécification de la propriété d'enregistrement automatique.

2. Le sérialiseur valide les enregistrements de données par rapport au schéma : lorsque l'application produisant des données a enregistré son schéma, le sérialiseur du registre de schémas valide l'enregistrement produit par l'application structurée avec les champs et les types de données correspondant à un schéma enregistré. Si le schéma de l'enregistrement ne correspond pas à un schéma enregistré, le sérialiseur renvoie une exception et l'application ne parvient pas à livrer l'enregistrement à la destination.

Si aucun schéma n'existe et si le nom du schéma n'est pas fourni via les configurations du producteur, le schéma est créé avec le même nom que le nom de la rubrique (s'il s'agit d'Apache Kafka ou d'Amazon MSK) ou le nom du flux (s'il s'agit de Kinesis Data Streams).

Chaque enregistrement a une définition de schéma et des données. La définition du schéma est interrogée par rapport aux schémas et versions existants dans le registre de schémas.

Par défaut, les producteurs mettent en cache les définitions des schémas et les versions IDs des schémas enregistrés. Si la définition de version de schéma d'un enregistrement ne correspond pas à ce qui est disponible dans le cache, le producteur tentera de valider le schéma avec le registre de schémas. Si la version du schéma est valide, son ID de version et sa définition seront alors mis en cache localement sur le producteur.

Vous pouvez ajuster la période de mise en cache par défaut (24 heures) dans les propriétés facultatives du producteur à l'étape 3 de [Installation de SerDe bibliothèques](#).

3. Sérialiser et livrer des enregistrements : si l'enregistrement est conforme au schéma, le sérialiseur décore chaque enregistrement avec l'ID de version du schéma, sérialise l'enregistrement en fonction du format de données sélectionné (AVRO, JSON, Protobuf ou autres formats prochainement disponibles), compresse l'enregistrement (configuration du producteur facultative) et le livre à la destination.
4. Les applications consommateur désérialisent les données : les applications consommateur qui lisent ces données utilisent la bibliothèque du désérialiseur du registre de schémas qui analyse l'ID de version du schéma à partir de la charge utile de l'enregistrement.

5. Le désérialiseur peut demander le schéma à partir du registre de schémas : si c'est la première fois que le désérialiseur a constaté des enregistrements avec un ID de version de schéma particulier, à l'aide de l'ID de version de schéma, il demandera le schéma à partir du registre de schémas et mettra en cache le schéma localement sur l'application consommateur. Si le registre de schémas ne peut pas désérialiser l'enregistrement, l'application consommateur peut journaliser les données de l'enregistrement et continuer, mais aussi arrêter l'application.
6. Le désérialiseur utilise le schéma pour désérialiser l'enregistrement : lorsque le désérialiseur récupère l'ID de version de schéma auprès du registre de schémas, le désérialiseur décompresse l'enregistrement (si l'enregistrement envoyé par le producteur est compressé) et utilise le schéma pour désérialiser l'enregistrement. L'application traite à présent l'enregistrement.

Note

Chiffrement : vos clients communiquent avec le registre de schémas via des appels d'API qui chiffrent les données en transit à l'aide du chiffrement TLS sur HTTPS. Les schémas stockés dans le registre des schémas sont toujours chiffrés au repos à l'aide d'une clé gérée par le service AWS Key Management Service (AWS KMS).

Note

Autorisation de l'utilisateur : le registre de schémas prend en charge les politiques IAM basées sur l'identité.

Commencer à utiliser le registre des schémas

Les sections suivantes fournissent une présentation et vous expliquent comment configurer et utiliser le registre de schémas. Pour plus d'informations sur les concepts et les composants du registre de schémas, consultez [AWS Glue Registre de schémas](#).

Rubriques

- [Installation de SerDe bibliothèques](#)
- [Création d'un registre](#)
- [Création d'un schéma](#)
- [Mise à jour d'un schéma ou d'un registre](#)

- [Suppression d'un schéma ou d'un registre](#)
- [Exemples d'IAM pour les sérialiseurs](#)
- [Exemples d'IAM pour les désérialiseurs](#)
- [Connectivité privée à l'aide de AWS PrivateLink](#)
- [Accès aux CloudWatch métriques d'Amazon](#)
- [Exemple de AWS CloudFormation modèle pour le registre de schémas](#)

Installation de SerDe bibliothèques

Note

Prérequis : avant d'effectuer les étapes suivantes, vous devez avoir un Amazon Managed Streaming for Apache Kafka (Amazon MSK) ou un cluster Apache Kafka en cours d'exécution. Vos applications producteur et consommateur doivent utiliser Java 8 ou une version supérieure.

Les SerDe bibliothèques fournissent un cadre pour la sérialisation et la désérialisation des données.

Vous allez installer le sérialiseur open source pour vos applications produisant des données (collectivement les « sérialiseurs »). Le sérialiseur gère la sérialisation, la compression et l'interaction avec le registre de schémas. Le sérialiseur extrait automatiquement le schéma d'un enregistrement en cours d'écriture vers une destination compatible avec le registre de schémas, telle qu'Amazon MSK. De même, vous allez installer le désérialiseur open source sur vos applications consommant des données.

Pour installer les bibliothèques sur les applications producteur et consommateur :

1. Dans les fichiers pom.xml des applications producteur et consommateur, ajoutez cette dépendance via le code ci-dessous :

```
<dependency>
  <groupId>software.amazon.glue</groupId>
  <artifactId>schema-registry-serde</artifactId>
  <version>1.1.5</version>
</dependency>
```

Vous pouvez également cloner le [AWS Glue Référentiel](#) Github du registre des schémas.

2. Configurez vos applications producteur avec les propriétés requises suivantes :

```
props.put(ProducerConfig.KEY_SERIALIZER_CLASS_CONFIG,
StringSerializer.class.getName()); // Can replace StringSerializer.class.getName()
with any other key serializer that you may use
props.put(ProducerConfig.VALUE_SERIALIZER_CLASS_CONFIG,
GlueSchemaRegistryKafkaSerializer.class.getName());
props.put(AWSSchemaRegistryConstants.AWS_REGION, "us-east-2");
properties.put(AWSSchemaRegistryConstants.DATA_FORMAT, "JSON"); // OR "AVRO"
```

S'il n'existe aucun schéma existant, l'enregistrement automatique doit être activé (étape suivante). Si vous avez un schéma que vous souhaitez appliquer, remplacez « my-schema » par le nom de votre schéma. La valeur « registry-name » doit également être fournie si l'enregistrement automatique du schéma est désactivé. Si le schéma est créé sous la valeur « default-registry », le nom du registre peut être omis.

3. (Facultatif) Définissez l'une de ces propriétés de producteur facultatives. Pour une description détaillée des propriétés, consultez [le ReadMe fichier](#).

```
props.put(AWSSchemaRegistryConstants.SCHEMA_AUTO_REGISTRATION_SETTING, "true"); // If
not passed, uses "false"
props.put(AWSSchemaRegistryConstants.SCHEMA_NAME, "my-schema"); // If not passed,
uses transport name (topic name in case of Kafka, or stream name in case of Kinesis
Data Streams)
props.put(AWSSchemaRegistryConstants.REGISTRY_NAME, "my-registry"); // If not passed,
uses "default-registry"
props.put(AWSSchemaRegistryConstants.CACHE_TIME_TO_LIVE_MILLIS, "86400000"); // If
not passed, uses 86400000 (24 Hours)
props.put(AWSSchemaRegistryConstants.CACHE_SIZE, "10"); // default value is 200
props.put(AWSSchemaRegistryConstants.COMPATIBILITY_SETTING, Compatibility.FULL); //
Pass a compatibility mode. If not passed, uses Compatibility.BACKWARD
props.put(AWSSchemaRegistryConstants.DESCRPTION, "This registry is used for several
purposes."); // If not passed, constructs a description
props.put(AWSSchemaRegistryConstants.COMPRESSION_TYPE,
AWSSchemaRegistryConstants.COMPRESSION.ZLIB); // If not passed, records are sent
uncompressed
```

L'enregistrement automatique enregistre la version du schéma sous le registre par défaut (« default-registry »). Si une valeur SCHEMA_NAME n'est pas spécifiée à l'étape précédente, le nom de la rubrique est alors déduit comme étant SCHEMA_NAME.

Pour de plus amples informations sur les modes de compatibilité, veuillez consulter [Gestion des versions et compatibilité des schémas](#).

4. Configurez vos applications consommateur avec les propriétés requises suivantes :

```
props.put(ConsumerConfig.KEY_DESERIALIZER_CLASS_CONFIG,
    StringDeserializer.class.getName());
props.put(ConsumerConfig.VALUE_DESERIALIZER_CLASS_CONFIG,
    GlueSchemaRegistryKafkaDeserializer.class.getName());
props.put(AWSSchemaRegistryConstants.AWS_REGION, "us-east-2"); // Pass an Région AWS
props.put(AWSSchemaRegistryConstants.AVRO_RECORD_TYPE,
    AvroRecordType.GENERIC_RECORD.getName()); // Only required for AVRO data format
```

5. (Facultatif) Définissez ces propriétés d'application consommateur facultatives. Pour une description détaillée des propriétés, consultez [le ReadMe fichier](#).

```
properties.put(AWSSchemaRegistryConstants.CACHE_TIME_TO_LIVE_MILLIS, "86400000"); //
    If not passed, uses 86400000
props.put(AWSSchemaRegistryConstants.CACHE_SIZE, "10"); // default value is 200
props.put(AWSSchemaRegistryConstants.SECONDARY_DESERIALIZER,
    "com.amazonaws.services.schemaregistry.deserializers.external.ThirdPartyDeserializer"); //
    For migration fall back scenario
```

Création d'un registre

Vous pouvez utiliser le registre par défaut ou créer autant de nouveaux registres que nécessaire à l'aide du AWS Glue APIs ou AWS Glue console.

AWS Glue APIs

Vous pouvez suivre ces étapes pour effectuer cette tâche à l'aide du AWS Glue APIs.

Pour utiliser le AWS CLI pour AWS Glue Registre des schémas APIs, assurez-vous de mettre à jour votre version AWS CLI vers la dernière version.

Pour ajouter un nouveau registre, utilisez l'API [CreateRegistry action \(Python : create_registry\)](#). Spécifiez RegistryName comme nom du registre à créer, avec une longueur maximale de 255, contenant uniquement des lettres, des chiffres, des traits d'union, des traits de soulignement, le symbole dollar ou le dièse.

Spécifiez a Description sous forme de chaîne d'une longueur maximale de 2 048 octets, correspondant au modèle de [chaîne multiligne de l'adresse URI](#).

Vous pouvez également spécifier une ou plusieurs Tags pour votre registre, sous forme de tableau de mappage de paires clé-valeur.

```
aws glue create-registry --registry-name registryName1 --description description
```

Lorsque votre registre est créé, il se voit attribuer un Amazon Resource Name (ARN), que vous pouvez consulter dans le RegistryArn de la réponse de l'API. Maintenant que vous avez créé un registre, créez un ou plusieurs schémas pour ce registre.

AWS Glue console

Pour ajouter un nouveau registre dans AWS Glue console :

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous Data catalog (Catalogue de données), choisissez Schema registries (Registres de schémas).
3. Choisissez Add registry (Ajouter un registre).
4. Saisissez un nom du registre à donner au registre, composé de lettres, de chiffres, de traits d'union et de traits de soulignement. Ce nom ne peut pas être modifié.
5. Saisissez une description (facultatif) pour le registre.
6. Si vous le souhaitez, appliquez une ou plusieurs balises à votre registre. Choisissez Add new tag (Ajouter une nouvelle balise) et spécifiez une clé de balise, et éventuellement une valeur de balise.
7. Choisissez Add registry (Ajouter un registre).

AWS Glue

Data catalog

Databases

Tables

Connections

Crawlers

Classifiers

Schema registries

Schemas

Settings

ETL

AWS Glue Studio

New

Workflows

Jobs

ML Transforms

Triggers

Dev endpoints

Notebooks

Schema registries > Add registry

Add a new schema registry

Add a schema registry to store one or multiple new related schemas.

Registry name
Name can't be changed post creation.

Enter a registry name...

Only letters (A-Z), numbers (0-9), hyphens (-), underscores (_), dollar signs (\$), or hash marks (#) allowed. 255 characters maximum.

Description - optional

Enter a registry description...

2048 characters maximum.

Registry tags - optional
No tags defined.

Add new tag

You can add up to 50 more tags.

Cancel Add registry

Lorsque votre registre est créé, un Amazon Resource Name (ARN) lui est attribué, que vous pouvez consulter en choisissant le registre dans la liste Schema registries (Registres de schémas). Maintenant que vous avez créé un registre, créez un ou plusieurs schémas pour ce registre.

Traiter un enregistrement spécifique (JAVA POJO) pour JSON

Vous pouvez utiliser un ancien objet Java simple (POJO) et transmettre l'objet en tant qu'enregistrement. Ceci est similaire à la notion d'enregistrement spécifique dans AVRO. Ils [mbknor-jackson-jjsonschema](#) peuvent générer un schéma JSON pour le POJO transmis. Cette bibliothèque peut également injecter des informations supplémentaires dans le schéma JSON.

Le AWS Glue La bibliothèque Schema Registry utilise le champ « ClassName » injecté dans le schéma pour fournir un nom de classe entièrement classé. Le champ « ClassName » est utilisé par le désérialiseur pour désérialiser dans un objet de cette classe.

Example class :

```
@JsonSchemaDescription("This is a car")
```

```
@JsonSchemaTitle("Simple Car Schema")
@Builder
@AllArgsConstructor
@EqualsAndHashCode
// Fully qualified class name to be added to an additionally injected property
// called className for deserializer to determine which class to deserialize
// the bytes into
@JsonSchemaInject(
    strings = {@JsonSchemaString(path = "className",
        value =
            "com.amazonaws.services.schemaregistry.integrationtests.generators.Car")})
)
// List of annotations to help infer JSON Schema are defined by https://github.com/
mbknor/mbknor-jackson-jsonSchema
public class Car {
    @JsonProperty(required = true)
    private String make;

    @JsonProperty(required = true)
    private String model;

    @JsonSchemaDefault("true")
    @JsonProperty
    public boolean used;

    @JsonSchemaInject(ints = {@JsonSchemaInt(path = "multipleOf", value = 1000)})
    @Max(200000)
    @JsonProperty
    private int miles;

    @Min(2000)
    @JsonProperty
    private int year;

    @JsonProperty
    private Date purchaseDate;

    @JsonProperty
    @JsonFormat(shape = JsonFormat.Shape.NUMBER)
    private Date listedDate;

    @JsonProperty
    private String[] owners;
```

```
@JsonProperty
private Collection<Float> serviceChecks;

// Empty constructor is required by Jackson to deserialize bytes
// into an Object of this class
public Car() {}
}
```

Création d'un schéma

Vous pouvez créer un schéma à l'aide du AWS Glue APIs ou le AWS Glue console.

AWS Glue APIs

Vous pouvez suivre ces étapes pour effectuer cette tâche à l'aide du AWS Glue APIs.

Pour ajouter un nouveau schéma, utilisez l'API [CreateSchema action \(Python : créer schéma\)](#).

Spécifiez une structure RegistryId pour indiquer un registre pour le schéma. Ou, omettez la valeur RegistryId pour utiliser le registre par défaut.

Spécifiez une valeur SchemaName composée de lettres, de chiffres, de traits d'union et de traits de soulignement, ainsi qu'une valeur DataFormat comme **AVRO** ou **JSON**. Une fois la valeur DataFormat définie sur un schéma, elle n'est pas modifiable.

Spécifiez un mode Compatibility :

- Backward (Descendant) (recommandé) — L'application consommateur peut lire à la fois la version actuelle et précédente.
- Backward all (Descendant tout) — L'application consommateur peut lire les versions actuelles et toutes les versions précédentes.
- Forward (Ascendant) — L'application consommateur peut lire à la fois la version actuelle et la version ultérieure.
- Forward all (Ascendant tout) — L'application consommateur peut lire à la fois les versions actuelles et les versions ultérieures.
- Full (Complet) — Combinaison de Forward (Ascendant) et de Backward (Descendant).
- Full all (Complet tout) — Combinaison de Backward all (Descendant tout) et de Forward all (Ascendant tout).

- None (Aucun) — Aucune vérification de compatibilité n'est effectuée.
- Disabled (Désactivé) — Empêche toute gestion des versions pour ce schéma.

Le cas échéant, spécifiez Tags pour votre schéma.

Spécifiez une valeur SchemaDefinition pour définir le schéma au format de données Avro, JSON ou Protobuf. Veuillez consulter les exemples.

Pour le format de données Avro :

```
aws glue create-schema --registry-id RegistryName="registryName1" --schema-name
testschema --compatibility NONE --data-format AVRO --schema-definition "{\"type\":
\\record\\\", \\name\\\": \\r1\\\", \\fields\\\": [ {\\name\\\": \\f1\\\", \\type\\\": \\int\\\",
{\\name\\\": \\f2\\\", \\type\\\": \\string\\\"} ]}\"
```

```
aws glue create-schema --registry-id RegistryArn="arn:aws:glue:us-
east-2:901234567890:registry/registryName1" --schema-name testschema --compatibility
NONE --data-format AVRO --schema-definition "{\"type\": \\record\\\", \\name\\\": \\r1\\\",
\\fields\\\": [ {\\name\\\": \\f1\\\", \\type\\\": \\int\\\", {\\name\\\": \\f2\\\", \\type\\\":
\\string\\\"} ]}\"
```

Pour le format de données JSON :

```
aws glue create-schema --registry-id RegistryName="registryName" --schema-name
testSchemaJson --compatibility NONE --data-format JSON --schema-definition "{\"$schema
\\\": \\http://json-schema.org/draft-07/schema#\\\", \\type\\\": \\object\\\", \\properties\\\":
{\\f1\\\": {\\type\\\": \\string\\\"}}}\"
```

```
aws glue create-schema --registry-id RegistryArn="arn:aws:glue:us-
east-2:901234567890:registry/registryName" --schema-name testSchemaJson --compatibility
NONE --data-format JSON --schema-definition "{\"$schema\\\": \\http://json-schema.org/
draft-07/schema#\\\", \\type\\\": \\object\\\", \\properties\\\": {\\f1\\\": {\\type\\\": \\string\\\"}}}\"
```

Pour le format de données Protobuf :

```
aws glue create-schema --registry-id RegistryName="registryName" --schema-name
testSchemaProtobuf --compatibility NONE --data-format PROTOBUF --schema-definition
"syntax = \\proto2\\\";package org.test;message Basic { optional int32 basic = 1;}"
```



```
aws glue create-schema --registry-id RegistryArn="arn:aws:glue:us-east-2:901234567890:registry/registryName" --schema-name testSchemaProtobuf --compatibility NONE --data-format PROTOBUF --schema-definition "syntax = \"proto2\";package org.test;message Basic { optional int32 basic = 1;}"
```

AWS Glue console

Pour ajouter un nouveau schéma à l'aide du AWS Glue console :

1. Connectez-vous à la console AWS de gestion et ouvrez AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous Data catalog (Catalogue de données), choisissez Schemas (Schémas).
3. Choisissez Add schema (Ajouter un schéma).
4. Saisissez un nom de schéma, composé de lettres, de chiffres, de traits d'union, de traits de soulignement, de symboles dollar ou de dièses. Ce nom ne peut pas être modifié.
5. Cliquez sur l'onglet Registry (Registre) où le schéma sera stocké à partir du menu déroulant. Le registre parent ne peut pas être modifié après la création.
6. Quitter le format de données en tant qu'Apache Avro ou JSON. Ce format s'applique à toutes les versions de ce schéma.
7. Choisissez un mode de compatibilité.
 - Backward (Descendant) (recommandé) — Le récepteur peut lire à la fois les versions actuelles et précédentes.
 - Backward All (Descendant tout) — Le récepteur peut lire les versions actuelles et toutes les versions précédentes.
 - Forward (Ascendant) — L'expéditeur peut écrire à la fois les versions actuelles et précédentes.
 - Forward all (Ascendant tout) — L'expéditeur peut écrire la version actuelle et toutes les versions précédentes.
 - Full (Complet) — Combinaison de Forward (Ascendant) et de Backward (Descendant).
 - Full All (Complet tout) — Combinaison de Backward All (Descendant tout) et de Forward All (Ascendant tout).
 - None (Aucun) — Aucune vérification de compatibilité n'est effectuée.
 - Disabled (Désactivé) — Empêche toute gestion des versions pour ce schéma.
8. Saisissez une description facultative pour le registre de 250 caractères maximum.

AWS Glue

Data catalog

Databases

Tables

Connections

Crawlers

Classifiers

Schema registries

Schemas

Settings

ETL

AWS Glue Studio

New

Workflows

Jobs

ML Transforms

Triggers

Dev endpoints

Notebooks

Security

Security configurations

Tutorials

Add crawler

Explore table

Add job

Resources What's new

Schemas > Add schema

Add a new schema

Specify your new schema name, properties, and schema definition.

Schema name

Name can't be changed post creation.

Only letters (A-Z), numbers (0-9), hyphens (-), underscores (_), dollar signs (\$), or hash marks (#) allowed. 255 characters maximum.

Registry

Parent registry can't be changed post creation.

[Add new registry](#)

Data format

Glue schemas only support Apache Avro for now, which offers the compatibility options below. [Learn more](#) 

Compatibility mode

Compatibility may be changed post creation and affects data senders and/or receivers.

**Backward compatibility** [Learn more](#)

This compatibility choice allows consumers to read both the current and the previous schema version. This means that for instance, a new schema version cannot drop data fields or change the type of these fields, so they can't be read by consumers using the previous version.

Description - optional

2048 characters maximum.

9. Si vous le souhaitez, appliquez une ou plusieurs balises à votre schéma. Choisissez Add new tag (Ajouter une nouvelle balise) et spécifiez une clé de balise, et éventuellement une valeur de balise.

10 Dans la case First schema version (Première version de schéma), saisissez ou collez votre schéma initial.

Pour le format Avro, voir [Utilisation du format de données Avro](#)

Pour le format JSON, voir [Utilisation du format de données JSON](#)

11.Choisissez éventuellement Add metadata (Ajouter des métadonnées) pour ajouter des métadonnées de version afin d'annoter ou de classer votre version de schéma.

12.Choisissez Create schema and version (Créer un schéma et une version).

AWS Glue

- Data catalog
- Databases
 - Tables
 - Connections
- Crawlers
- Classifiers
- Schema registries
- Schemas**
- Settings
- ETL
- AWS Glue Studio
- New
- Blueprints
- Workflows
- Jobs
 - ML Transforms
- Triggers
- Dev endpoints
- Notebooks
- Security
- Security configurations
- Tutorials
- Add crawler
- Explore table
- Add job
- Resources

Schema tags - optional
No tags defined.

[Add new tag](#)

You can add up to 50 more tags.

First schema version
Please specify the initial definition of your schema below, so that it can be used in your applications or within Amazon Glue. You may change your schema definition by registering new versions at any point later. Please enter Apache Avro schema below. [Learn more](#)

1

Version metadata - optional
No metadata key-value pairs.

[Add metadata](#)

You can add 10 more metadata key-value pairs.

[Cancel](#) [Create schema and version](#)

Le schéma est créé et apparaît dans la liste sous Schemas (Schémas).

Utilisation du format de données Avro

Avro fournit des services de sérialisation et d'échange de données. Avro stocke la définition des données au format JSON, ce qui la rend facile à lire et à interpréter. Les données elles-mêmes sont stockées au format binaire.

Pour plus d'informations sur la définition d'un schéma Apache Avro, veuillez consulter la [spécification d'Apache Avro](#).

Utilisation du format de données JSON

Les données peuvent être sérialisées au format JSON. Le [format de schéma JSON](#) définit la norme pour le format de schéma JSON.

Mise à jour d'un schéma ou d'un registre

Une fois créés, vous pouvez modifier vos schémas, vos versions de schéma ou votre registre.

Mise à jour d'un registre

Vous pouvez mettre à jour un registre à l'aide du AWS Glue APIs ou le AWS Glue console. Le nom d'un registre existant ne peut pas être modifié. Vous pouvez modifier la description d'un registre.

AWS Glue APIs

Pour mettre à jour un registre existant, utilisez l'API [UpdateRegistry action \(Python : update_registry\)](#).

Spécifiez une structure RegistryId pour indiquer le registre que vous souhaitez mettre à jour. Transmettez une Description pour modifier la description d'un registre.

```
aws glue update-registry --description updatedDescription --registry-id
RegistryArn="arn:aws:glue:us-east-2:901234567890:registry/registryName1"
```

AWS Glue console

Pour mettre à jour un registre à l'aide du AWS Glue console :

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous Data catalog (Catalogue de données), choisissez Schema registries (Registres de schémas).

3. Sélectionnez un registre dans la liste des registres, en cochant sa case.
4. Dans le menu Action, choisissez Edit registry (Modifier un registre).

Mise à jour d'un schéma

Vous pouvez mettre à jour le paramètre de description ou de compatibilité pour un schéma.

Pour mettre à jour un schéma existant, utilisez l'API [UpdateSchema action \(Python : `update\_schema`\)](#).

Spécifiez une structure SchemaId pour indiquer le schéma que vous souhaitez mettre à jour. VersionNumber ou Compatibility doit être fourni.

Exemple de code 11 :

```
aws glue update-schema --description testDescription --schema-id
  SchemaName="testSchema1",RegistryName="registryName1" --schema-version-number
  LatestVersion=true --compatibility NONE
```

```
aws glue update-schema --description testDescription --schema-id
  SchemaArn="arn:aws:glue:us-east-2:901234567890:schema/registryName1/testSchema1" --
  schema-version-number LatestVersion=true --compatibility NONE
```

Ajout d'une version de schéma

Lorsque vous ajoutez une version de schéma, vous devez comparer les versions pour vous assurer que le nouveau schéma sera accepté.

Pour ajouter une nouvelle version à un schéma existant, utilisez l'API [RegisterSchemaVersion action \(Python : `register\_schema\_version`\)](#).

Spécifiez une structure SchemaId pour indiquer le schéma pour lequel vous souhaitez ajouter une version, ainsi qu'une valeur SchemaDefinition pour définir le schéma.

Exemple de code 12 :

```
aws glue register-schema-version --schema-definition '{"type": "record", "name":
  "r1", "fields": [ {"name": "f1", "type": "int"}, {"name": "f2", "type
  ": "string"} ]}' --schema-id SchemaArn="arn:aws:glue:us-east-1:901234567890:schema/
  registryName/testschema"
```

```
aws glue register-schema-version --schema-definition "{\"type\": \"record\", \"name\": \"r1\", \"fields\": [ {\"name\": \"f1\", \"type\": \"int\"}, {\"name\": \"f2\", \"type\": \"string\"} ]}" --schema-id SchemaName="testschema",RegistryName="testregistry"
```

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous Data catalog (Catalogue de données), choisissez Schemas (Schémas).
3. Sélectionnez le schéma dans la liste des schémas, en cochant sa case.
4. Sélectionnez un ou plusieurs schémas dans la liste, en cochant les cases.
5. Dans le menu Action, choisissez Register new version (Enregistrer une nouvelle version).
6. Dans New version (Nouvelle version), saisissez ou collez votre nouveau schéma.
7. Choisissez Compare with previous version (Comparer avec la version précédente) pour voir les différences avec la version de schéma précédente.
8. Choisissez éventuellement Add metadata (Ajouter des métadonnées) pour ajouter des métadonnées de version afin d'annoter ou de classer votre version de schéma. Saisissez une clé et une valeur facultative.
9. Choisissez Register version (Version de registre).

AWS Glue

Data catalog

Databases

Tables

Connections

Crawlers

Classifiers

Schema registries

Schemas

Settings

ETL

AWS Glue Studio

New

Blueprints

Workflows

Jobs

ML Transforms

Triggers

Dev endpoints

Notebooks

Security

Security configurations

Tutorials

Add crawler

Explore table

Add job

Schemas > test-1 > Register version

Register a new schema version

Register version 4 to your schema.

Schema name	test-1
Data format	Apache Avro
Compatibility mode	Backward compatibility
Schema tags	No tags defined.

New Version 4

This is a copy of version 1's schema definition. A schema definition not associated with any existing schema versions must be defined in order to register a new schema version.

```
1  {  
2    "type": "record",  
3    "name": "r0",  
4    "fields": [  
5      {  
6        "name": "f1",  
7        "type": "int"  
8      }  
9    ]  
10 }
```

[Compare with previous version](#)

Version metadata - optional

No metadata key-value pairs.

[Add metadata](#)

You can add 10 more metadata key-value pairs.

[Cancel](#)[Register version](#)

La version du ou des schémas s'affiche dans la liste des versions. Si la version a changé le mode de compatibilité, la version sera marquée comme point de contrôle.

Exemple de comparaison d'une version de schéma

Lorsque vous choisissez [Compare with previous version](#) (Comparer avec la version précédente), vous verrez les versions précédentes et les nouvelles versions affichées ensemble. Les informations modifiées seront mises en évidence comme suit :

- Jaune : indique les informations modifiées.
- Vert : indique le contenu ajouté à la dernière version.
- Rouge : indique le contenu supprimé dans la dernière version.

Vous pouvez également comparer les versions antérieures.

Schema version comparison

Schema test-1

Compatibility Mode Backward compatibility

Version 1 (latest a... ▾)

Version 4 (new) ▾

```

1 {
2   "type": "record",
3-  "name": "r0",
4   "fields": [
5     {
6       "name": "f1",
7       "type": "int"
8     }
9   ]
10 }

```

```

1 {
2   "type": "record",
3+  "name": "user.record",
4+  "aliases": "userInfo",
5   "fields": [
6     {
7       "name": "f1",
8       "type": "int"
9     }
10  ]
11 }

```

Registered Thu, 01 Oct 2020 17:37:19 GMT

Registered -

Metadata -

Metadata -

Close

Suppression d'un schéma ou d'un registre

La suppression d'un schéma, d'une version de schéma ou d'un registre est une action permanente qui ne peut pas être annulée.

Suppression d'un schéma

Vous souhaitez peut-être supprimer un schéma lorsqu'il ne sera plus utilisé dans un registre, à l'aide de l' [AWS Management Console API](#) ou de l' [DeleteSchema action \(Python : supprimer_schéma\)](#) API.

La suppression d'un ou plusieurs schémas est une action permanente qui ne peut pas être annulée. Assurez-vous que le ou les schémas ne sont plus nécessaires.

Pour supprimer un schéma du registre, appelez l'API [DeleteSchema action \(Python : supprimer_schéma\)](#), en spécifiant la structure SchemaId pour identifier le schéma.

Par exemple :

```
aws glue delete-schema --schema-id SchemaArn="arn:aws:glue:us-east-2:901234567890:schema/registryName1/schemaname"
```

```
aws glue delete-schema --schema-id SchemaName="TestSchema6-deleteschemabynome",RegistryName="default-registry"
```

AWS Glue console

Pour supprimer un schéma du AWS Glue console :

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous Data catalog (Catalogue de données), choisissez Schema registries (Registres de schémas).
3. Choisissez le registre qui contient votre schéma dans la liste des registres.
4. Sélectionnez un ou plusieurs schémas dans la liste, en cochant les cases.
5. Dans le menu Action, sélectionnez Delete schema (Supprimer un schéma).
6. Saisissez le texte **Delete** dans le champ pour confirmer la suppression.
7. Choisissez Delete (Supprimer).

Le ou les schémas que vous avez spécifiés sont supprimés du registre.

Suppression d'une version de schéma

Au fur et à mesure que les schémas s'accumulent dans le registre, vous souhaitez peut-être supprimer les versions de schéma indésirables à l'aide de l' AWS Management Console API ou de l'[DeleteSchemaVersions action \(Python : delete_schema_versions\)](#)API. La suppression d'une ou de plusieurs versions de schéma est une action permanente qui ne peut pas être annulée. Assurez-vous que les versions de schéma ne sont plus nécessaires.

Lorsque vous supprimez des versions de schéma, veuillez tenir compte des contraintes suivantes :

- Vous ne pouvez pas supprimer une version comportant un point de contrôle.
- La gamme de versions contiguës ne peut pas dépasser 25.
- La version de schéma la plus récente ne doit pas être dans un état en attente.

Spécifiez la structure SchemaId pour identifier le schéma et spécifiez Versions comme une plage de versions à supprimer. Pour plus d'informations sur la spécification d'une version ou d'une plage de versions, veuillez consulter [DeleteRegistry action \(Python : supprimer_registre\)](#). Les versions de schéma que vous avez spécifiées sont supprimées du registre.

En appelant l'API [ListSchemaVersions action \(Python : list_schema_versions\)](#) après cet appel, vous obtiendrez la liste de l'état des versions supprimées.

Par exemple :

```
aws glue delete-schema-versions --schema-id  
SchemaName="TestSchema6",RegistryName="default-registry" --versions "1-1"
```

```
aws glue delete-schema-versions --schema-id SchemaArn="arn:aws:glue:us-  
east-2:901234567890:schema/default-registry/TestSchema6-NON-Existent" --versions "1-1"
```

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous Data catalog (Catalogue de données), choisissez Schema registries (Registres de schémas).
3. Choisissez le registre qui contient votre schéma dans la liste des registres.
4. Sélectionnez un ou plusieurs schémas dans la liste, en cochant les cases.
5. Dans le menu Action, sélectionnez Delete schema (Supprimer un schéma).
6. Saisissez le texte **Delete** dans le champ pour confirmer la suppression.
7. Choisissez Delete (Supprimer).

Les versions de schéma que vous avez spécifiées sont supprimées du registre.

Suppression d'un registre

Vous pouvez supprimer un registre lorsque les schémas qu'il contient ne doivent plus être organisés sous ce registre. Vous devrez réaffecter ces schémas à un autre registre.

La suppression d'un ou de plusieurs registres est une action permanente qui ne peut pas être annulée. Assurez-vous que le ou les registres ne sont plus requis.

Le registre par défaut peut être supprimé à l'aide de la AWS CLI.

AWS Glue « Hello, World! »

Pour supprimer l'intégralité du registre, y compris le schéma et toutes ses versions, appelez l'API [DeleteRegistry action \(Python : supprimer_registre\)](#). Spécifiez une structure RegistryId pour identifier le registre.

Par exemple :

```
aws glue delete-registry --registry-id RegistryArn="arn:aws:glue:us-east-2:901234567890:registry/registryName1"
```

```
aws glue delete-registry --registry-id RegistryName="TestRegistry-deletebyname"
```

Pour obtenir le statut de l'opération de suppression, vous pouvez appeler l'API GetRegistry après l'appel asynchrone.

AWS Glue console

Pour supprimer un registre du AWS Glue console :

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous Data catalog (Catalogue de données), choisissez Schema registries (Registres de schémas).
3. Sélectionnez un registre dans la liste en cochant une case.
4. Dans le menu Action, choisissez Delete registry (Supprimer un registre).
5. Saisissez le texte **Delete** dans le champ pour confirmer la suppression.
6. Choisissez Delete (Supprimer).

Les registres que vous avez sélectionnés sont supprimés de AWS Glue.

Exemples d'IAM pour les sérialiseurs

Note

AWS les politiques gérées accordent les autorisations nécessaires pour les cas d'utilisation courants. Pour plus d'informations sur l'utilisation des politiques gérées pour gérer le registre de schéma, veuillez consulter [AWS politiques gérées \(prédéfinies\) pour AWS Glue](#).

Pour les sérialiseurs, vous devez créer une politique minimale similaire à celle ci-dessous pour vous donner la possibilité de trouver le `schemaVersionId` pour une définition de schéma donnée. Notez que vous devez disposer des autorisations de lecture sur le registre afin de lire les schémas dans le registre. Vous pouvez limiter les registres qui peuvent être lus à l'aide de la clause `Resource`.

Exemple de code 13 :

```
{
  "Sid" : "GetSchemaByDefinition",
  "Effect" : "Allow",
  "Action" :
  [
    "glue:GetSchemaByDefinition"
  ],
  "Resource" : ["arn:aws:glue:us-east-2:012345678:registry/registryname-1",
                "arn:aws:glue:us-east-2:012345678:schema/registryname-1/
schemaname-1",
                "arn:aws:glue:us-east-2:012345678:schema/registryname-1/
schemaname-2"
              ]
}
```

En outre, vous pouvez également autoriser les applications producteur à créer des schémas et versions en incluant les méthodes supplémentaires suivantes. Notez que vous devriez être en mesure d'inspecter le registre afin de vérifier `add/remove/evolve` les schémas qu'il contient. Vous pouvez limiter les registres qui peuvent être inspectés à l'aide de la clause `Resource`.

Exemple de code 14 :

```
{
```

```
{
  "Sid" : "RegisterSchemaWithMetadata",
  "Effect" : "Allow",
  "Action" :
  [
    "glue:GetSchemaByDefinition",
    "glue:CreateSchema",
    "glue:RegisterSchemaVersion",
    "glue:PutSchemaVersionMetadata",
  ],
  "Resource" : ["arn:aws:glue:aws-region:123456789012:registry/registryname-1",
    "arn:aws:glue:aws-region:123456789012:schema/registryname-1/
schemaname-1",
    "arn:aws:glue:aws-region:123456789012:schema/registryname-1/
schemaname-2"
  ]
}
```

Exemples d'IAM pour les désérialiseurs

Pour les désérialiseurs (côté application consommateur), vous devez créer une politique similaire à celle ci-dessous pour autoriser le désérialiseur à récupérer le schéma à partir du registre de schéma pour la désérialisation. Notez que vous devriez être en mesure d'inspecter le registre afin d'extraire les schémas qu'il contient.

Exemple de code 15 :

```
{
  "Sid" : "GetSchemaVersion",
  "Effect" : "Allow",
  "Action" :
  [
    "glue:GetSchemaVersion"
  ],
  "Resource" : ["*"]
}
```

Connectivité privée à l'aide de AWS PrivateLink

Vous pouvez l'utiliser AWS PrivateLink pour connecter le VPC de votre producteur de données à AWS Glue en définissant un point de terminaison VPC d'interface pour AWS Glue. Lorsque vous utilisez un point de terminaison d'interface VPC, la communication entre votre VPC et AWS Glue est

entièrement réalisé au sein du AWS réseau. Pour plus d'informations, voir [Utilisation AWS Glue avec des points de terminaison VPC](#).

Accès aux CloudWatch métriques d'Amazon

Les CloudWatch statistiques Amazon sont disponibles dans le cadre CloudWatch de l'offre gratuite. Vous pouvez accéder à ces métriques dans la CloudWatch console. Les indicateurs au niveau de l'API incluent CreateSchema (succès et latence) GetSchemaByDefinition, (succès et latence), GetSchemaVersion (succès et latence), RegisterSchemaVersion (succès et latence), PutSchemaVersionMetadata (succès et latence). Les métriques au niveau des ressources incluent le registre. ThrottledByLimit, SchemaVersion. ThrottledByLimit, SchemaVersion .Taille.

Exemple de AWS CloudFormation modèle pour le registre de schémas

Voici un exemple de modèle pour créer des ressources de registre de schémas dans AWS CloudFormation. Pour créer cette pile dans votre compte, copiez le modèle ci-dessus dans un fichier `SampleTemplate.yaml` et exécutez la commande suivante :

```
aws cloudformation create-stack --stack-name ABCSchemaRegistryStack --template-body
  "'cat SampleTemplate.yaml'"
```

Cet exemple utilise `AWS::Glue::Registry` pour créer un registre, `AWS::Glue::Schema` pour créer un schéma, `AWS::Glue::SchemaVersion` pour créer une version de schéma et `AWS::Glue::SchemaVersionMetadata` pour renseigner les métadonnées de version de schéma.

```
Description: "A sample CloudFormation template for creating Schema Registry resources."
Resources:
  ABCRegistry:
    Type: "AWS::Glue::Registry"
    Properties:
      Name: "ABCSchemaRegistry"
      Description: "ABC Corp. Schema Registry"
      Tags:
        - Key: "Project"
          Value: "Foo"
  ABCSchema:
    Type: "AWS::Glue::Schema"
    Properties:
      Registry:
        Arn: !Ref ABCRegistry
      Name: "TestSchema"
```

```

Compatibility: "NONE"
DataFormat: "AVRO"
SchemaDefinition: >
  {"namespace":"foo.avro","type":"record","name":"user","fields":
[{"name":"name","type":"string"}, {"name":"favorite_number","type":"int"}]}
Tags:
  - Key: "Project"
    Value: "Foo"
SecondSchemaVersion:
  Type: "AWS::Glue::SchemaVersion"
  Properties:
    Schema:
      SchemaArn: !Ref ABCSchema
      SchemaDefinition: >
        {"namespace":"foo.avro","type":"record","name":"user","fields":
[{"name":"status","type":"string", "default":"ON"}, {"name":"name","type":"string"},
{"name":"favorite_number","type":"int"}]}
    FirstSchemaVersionMetadata:
      Type: "AWS::Glue::SchemaVersionMetadata"
      Properties:
        SchemaVersionId: !GetAtt ABCSchema.InitialSchemaVersionId
        Key: "Application"
        Value: "Kinesis"
    SecondSchemaVersionMetadata:
      Type: "AWS::Glue::SchemaVersionMetadata"
      Properties:
        SchemaVersionId: !Ref SecondSchemaVersion
        Key: "Application"
        Value: "Kinesis"

```

Intégration à AWS Glue Registre de schémas

Ces sections décrivent les intégrations avec AWS Glue registre de schémas. Les exemples présentés dans cette section montrent un schéma au format de données AVRO. Pour d'autres exemples, notamment des schémas au format de données JSON, consultez les tests d'intégration et les ReadMe informations dans le [AWS Glue Référentiel open source Schema Registry](#).

Rubriques

- [Cas d'utilisation : connexion du registre de schémas à Amazon MSK ou à Apache Kafka](#)
- [Cas d'utilisation : intégration d'Amazon Kinesis Data Streams à AWS Glue Registre de schémas](#)

- [Cas d'utilisation : Amazon Managed Service pour Apache Flink](#)
- [Cas d'utilisation : intégration avec AWS Lambda](#)
- [Cas d'utilisation : AWS Glue Data Catalog](#)
- [Cas d'utilisation : AWS Glue streaming](#)
- [Cas d'utilisation : Apache Kafka Streams](#)

Cas d'utilisation : connexion du registre de schémas à Amazon MSK ou à Apache Kafka

Supposons que vous écrivez des données sur une rubrique Apache Kafka, et que vous pouvez suivre ces étapes pour commencer.

1. Créez un cluster Amazon Managed Streaming for Apache Kafka (Amazon MSK) ou Apache Kafka avec au moins un sujet. Si vous créez un cluster Amazon MSK, vous pouvez utiliser la AWS Management Console. Suivez les instructions ci-après : [Mise en route avec Amazon MSK](#) dans le Guide du développeur Amazon Managed Streaming for Apache Kafka.
2. Suivez l'étape [Installation de SerDe bibliothèques](#) ci-dessus.
3. Pour créer des registres de schéma, des schémas ou des versions de schéma, suivez les instructions sous la section [Commencer à utiliser le registre des schémas](#) de ce document.
4. Faites en sorte que vos applications producteur et consommateur commencent à utiliser le registre de schémas pour écrire et lire des enregistrements vers/depuis la rubrique Amazon MSK ou Apache Kafka. Des exemples de code producteur et consommateur se trouvent dans [le ReadMe fichier](#) des bibliothèques Serde. La bibliothèque du registre de schémas du producteur sérialisera automatiquement l'enregistrement et décorera l'enregistrement avec un ID de version de schéma.
5. Si le schéma de cet enregistrement a été saisi, ou si l'enregistrement automatique est activé, le schéma aura été enregistré dans le registre de schémas.
6. Le consommateur lisant un extrait du sujet Amazon MSK ou Apache Kafka à l'aide du AWS Glue La bibliothèque de registre de schémas recherchera automatiquement le schéma dans le registre de schémas.

Cas d'utilisation : intégration d'Amazon Kinesis Data Streams à AWS Glue Registre de schémas

Cette intégration nécessite que vous ayez un flux de données Amazon Kinesis existant. Pour plus d'informations, veuillez consulter [Présentation des Amazon Kinesis Data Streams](#) dans le Guide du développeur Amazon Kinesis Data Streams.

Il existe deux façons d'interagir avec les données d'un flux de données Kinesis.

- Via les bibliothèques Kinesis Producer Library (KPL) et Kinesis Client Library (KCL) en Java. La prise en charge multilingue n'est pas fournie.
- Grâce au `PutRecordsPutRecord`, et aux `GetRecords` Kinesis Data APIs Streams disponibles dans le AWS SDK pour Java.

Si vous utilisez actuellement les bibliothèques KPL/KCL, nous vous recommandons de continuer à utiliser cette méthode. Il existe des versions KCL et KPL mises à jour avec le registre de schémas intégré, comme illustré dans les exemples. Sinon, vous pouvez utiliser l'exemple de code pour tirer parti du AWS Glue Registre des schémas si vous utilisez APIs directement le KDS.

L'intégration du registre de schémas n'est disponible qu'avec KPL version 0.14.2 ou ultérieure et avec KCL version 2.3 ou ultérieure. L'intégration du registre de schémas avec le format de données JSON est disponible avec KPL version 0.14.8 ou ultérieure et avec KCL version 2.3.6 ou ultérieure.

Interagir avec les données à l'aide du kit SDK Kinesis V2

Cette section décrit l'interaction avec Kinesis à l'aide du kit SDK Kinesis V2

```
// Example JSON Record, you can construct a AVRO record also
private static final JsonDataWithSchema record =
    JsonDataWithSchema.builder(schemaString, payloadString);
private static final DataFormat dataFormat = DataFormat.JSON;

//Configurations for Schema Registry
GlueSchemaRegistryConfiguration gsrConfig = new GlueSchemaRegistryConfiguration("us-
east-1");

GlueSchemaRegistrySerializer glueSchemaRegistrySerializer =
    new GlueSchemaRegistrySerializerImpl(awsCredentialsProvider, gsrConfig);
GlueSchemaRegistryDataFormatSerializer dataFormatSerializer =
    new GlueSchemaRegistrySerializerFactory().getInstance(dataFormat, gsrConfig);
```

```
Schema gsrSchema =
    new Schema(dataFormatSerializer.getSchemaDefinition(record), dataFormat.name(),
        "MySchema");

byte[] serializedBytes = dataFormatSerializer.serialize(record);

byte[] gsrEncodedBytes = glueSchemaRegistrySerializer.encode(streamName, gsrSchema,
    serializedBytes);

PutRecordRequest putRecordRequest = PutRecordRequest.builder()
    .streamName(streamName)
    .partitionKey("partitionKey")
    .data(SdkBytes.fromByteArray(gsrEncodedBytes))
    .build();
shardId = kinesisisClient.putRecord(putRecordRequest)
    .get()
    .shardId();

GlueSchemaRegistryDeserializer glueSchemaRegistryDeserializer = new
    GlueSchemaRegistryDeserializerImpl(awsCredentialsProvider, gsrConfig);

GlueSchemaRegistryDataFormatDeserializer gsrDataFormatDeserializer =
    glueSchemaRegistryDeserializerFactory.getInstance(dataFormat, gsrConfig);

GetShardIteratorRequest getShardIteratorRequest = GetShardIteratorRequest.builder()
    .streamName(streamName)
    .shardId(shardId)
    .shardIteratorType(ShardIteratorType.TRIM_HORIZON)
    .build();

String shardIterator = kinesisisClient.getShardIterator(getShardIteratorRequest)
    .get()
    .shardIterator();

GetRecordsRequest getRecordRequest = GetRecordsRequest.builder()
    .shardIterator(shardIterator)
    .build();
GetRecordsResponse recordsResponse = kinesisisClient.getRecords(getRecordRequest)
    .get();

List<Object> consumerRecords = new ArrayList<>();
List<Record> recordsFromKinesis = recordsResponse.records();

for (int i = 0; i < recordsFromKinesis.size(); i++) {
```

```

byte[] consumedBytes = recordsFromKinesis.get(i)
    .data()
    .asByteArray();

Schema gsrSchema = glueSchemaRegistryDeserializer.getSchema(consumedBytes);
Object decodedRecord =
gsrDataFormatDeserializer.deserialize(ByteBuffer.wrap(consumedBytes),

gsrSchema.getSchemaDefinition());
    consumerRecords.add(decodedRecord);
}

```

Interagir avec les données à l'aide des bibliothèques KPL/KCL

Cette section décrit l'intégration de Kinesis Data Streams à Schema Registry à l'aide de KPL/KCL libraries. For more information on using KPL/KCL la section [Developing Producers Using the Amazon Kinesis Producer Library dans le manuel Amazon Kinesis Data Streams Developer Guide](#).

Configuration du registre de schémas dans KPL

1. Définissez la définition du schéma pour les données, le format des données et le nom du schéma créés dans le AWS Glue Registre des schémas.
2. Le cas échéant, configurez l'objet `GlueSchemaRegistryConfiguration`.
3. Transmettez l'objet du schéma à `addUserRecord` API.

```

private static final String SCHEMA_DEFINITION = "{\"namespace\": \"example.avro\",\\n\"
+ \" \"type\": \"record\",\\n\"
+ \" \"name\": \"User\",\\n\"
+ \" \"fields\": [\\n\"
+ \" {\"name\": \"name\", \"type\": \"string\"},\\n\"
+ \" {\"name\": \"favorite_number\", \"type\": [\"int\", \"null\"]},\\n\"
+ \" {\"name\": \"favorite_color\", \"type\": [\"string\", \"null\"]}\\n\"
+ \" ]\\n\"
+ \"}\";

```

```

KinesisProducerConfiguration config = new KinesisProducerConfiguration();
config.setRegion("us-west-1")

```

```

//[Optional] configuration for Schema Registry.

```

```

GlueSchemaRegistryConfiguration schemaRegistryConfig =
new GlueSchemaRegistryConfiguration("us-west-1");

```

```

schemaRegistryConfig.setCompression(true);

config.setGlueSchemaRegistryConfiguration(schemaRegistryConfig);

///  
Optional configuration ends.

final KinesisProducer producer =
    new KinesisProducer(config);

final ByteBuffer data = getDataToSend();

com.amazonaws.services.schemaregistry.common.Schema gsrSchema =
    new Schema(SCHEMA_DEFINITION, DataFormat.AVRO.toString(), "demoSchema");

ListenableFuture<UserRecordResult> f = producer.addUserRecord(
    config.getStreamName(), TIMESTAMP, Utils.randomExplicitHashKey(), data, gsrSchema);

private static ByteBuffer getDataToSend() {
    org.apache.avro.Schema avroSchema =
        new org.apache.avro.Schema.Parser().parse(SCHEMA_DEFINITION);

    GenericRecord user = new GenericData.Record(avroSchema);
    user.put("name", "Emily");
    user.put("favorite_number", 32);
    user.put("favorite_color", "green");

    ByteArrayOutputStream outBytes = new ByteArrayOutputStream();
    Encoder encoder = EncoderFactory.get().directBinaryEncoder(outBytes, null);
    new GenericDatumWriter<>(avroSchema).write(user, encoder);
    encoder.flush();
    return ByteBuffer.wrap(outBytes.toByteArray());
}

```

Configuration de la bibliothèque client Kinesis

Vous allez développer votre application consommateur de la bibliothèque client Kinesis en Java. Pour de plus amples informations, veuillez consulter [Développement d'une application consommateur de la bibliothèque client Kinesis en Java](#) dans le Guide du développeur Amazon Kinesis Data Streams.

1. Créez une instance de `GlueSchemaRegistryDeserialzier` en transmettant un objet `GlueSchemaRegistryConfiguration`.

2. Transmettez le `GlueSchemaRegistryDeserializer` à `retrievalConfig.glueSchemaRegistryDeserializer`.
3. Accédez au schéma des messages entrants en appelant `kinesisClientRecord.getSchema()`.

```

GlueSchemaRegistryConfiguration schemaRegistryConfig =
    new GlueSchemaRegistryConfiguration(this.region.toString());

GlueSchemaRegistryDeserializer glueSchemaRegistryDeserializer =
    new
GlueSchemaRegistryDeserializerImpl(DefaultCredentialsProvider.builder().build(),
    schemaRegistryConfig);

RetrievalConfig retrievalConfig =
    configsBuilder.retrievalConfig().retrievalSpecificConfig(new
    PollingConfig(streamName, kinesisClient));
retrievalConfig.glueSchemaRegistryDeserializer(glueSchemaRegistryDeserializer);

Scheduler scheduler = new Scheduler(
    configsBuilder.checkpointConfig(),
    configsBuilder.coordinatorConfig(),
    configsBuilder.leaseManagementConfig(),
    configsBuilder.lifecycleConfig(),
    configsBuilder.metricsConfig(),
    configsBuilder.processorConfig(),
    retrievalConfig
);

public void processRecords(ProcessRecordsInput processRecordsInput) {
    MDC.put(SHARD_ID_MDC_KEY, shardId);
    try {
        log.info("Processing {} record(s)",
            processRecordsInput.records().size());
        processRecordsInput.records()
            .forEach(
                r ->
                    log.info("Processed record pk: {} -- Seq: {} : data {} with
schema: {}",
                        r.partitionKey(),
                        r.sequenceNumber(), recordToAvroObj(r).toString(), r.getSchema()));
    } catch (Throwable t) {
        log.error("Caught throwable while processing records. Aborting.");
        Runtime.getRuntime().halt(1);
    }
}

```

```

        } finally {
            MDC.remove(SHARD_ID_MDC_KEY);
        }
    }

    private GenericRecord recordToAvroObj(KinesisClientRecord r) {
        byte[] data = new byte[r.data().remaining()];
        r.data().get(data, 0, data.length);
        org.apache.avro.Schema schema = new
        org.apache.avro.Schema.Parser().parse(r.schema().getSchemaDefinition());
        DatumReader datumReader = new GenericDatumReader<>(schema);

        BinaryDecoder binaryDecoder = DecoderFactory.get().binaryDecoder(data, 0,
        data.length, null);
        return (GenericRecord) datumReader.read(null, binaryDecoder);
    }

```

Interaction avec les données à l'aide des Kinesis Data Streams APIs

Cette section décrit l'intégration de Kinesis Data Streams à Schema Registry à l'aide des Kinesis Data Streams. APIs

1. Mettez à jour ces dépendances Maven :

```

<dependencyManagement>
    <dependencies>
        <dependency>
            <groupId>com.amazonaws</groupId>
            <artifactId>aws-java-sdk-bom</artifactId>
            <version>1.11.884</version>
            <type>pom</type>
            <scope>import</scope>
        </dependency>
    </dependencies>
</dependencyManagement>

<dependencies>
    <dependency>
        <groupId>com.amazonaws</groupId>
        <artifactId>aws-java-sdk-kinesis</artifactId>
    </dependency>

```

```

<dependency>
  <groupId>software.amazon.glue</groupId>
  <artifactId>schema-registry-serde</artifactId>
  <version>1.1.5</version>
</dependency>

<dependency>
  <groupId>com.fasterxml.jackson.dataformat</groupId>
  <artifactId>jackson-dataformat-cbor</artifactId>
  <version>2.11.3</version>
</dependency>
</dependencies>

```

2. Dans l'application producteur, ajoutez des informations d'en-tête de schéma à l'aide de l'API PutRecords ou PutRecord dans Kinesis Data Streams.

```

//The following lines add a Schema Header to the record
com.amazonaws.services.schemaregistry.common.Schema awsSchema =
    new com.amazonaws.services.schemaregistry.common.Schema(schemaDefinition,
DataFormat.AVRO.name(),
    schemaName);
GlueSchemaRegistrySerializerImpl glueSchemaRegistrySerializer =
    new
GlueSchemaRegistrySerializerImpl(DefaultCredentialsProvider.builder().build(), new
GlueSchemaRegistryConfiguration(getConfigs()));
byte[] recordWithSchemaHeader =
    glueSchemaRegistrySerializer.encode(streamName, awsSchema,
recordAsBytes);

```

3. Dans l'application producteur, utilisez l'API PutRecords ou PutRecord pour placer l'enregistrement dans le flux de données.
4. Dans l'application consommateur, supprimez l'enregistrement de schéma de l'en-tête et sérialisez un enregistrement de schéma Avro.

```

//The following lines remove Schema Header from record
GlueSchemaRegistryDeserializerImpl glueSchemaRegistryDeserializer =
    new
GlueSchemaRegistryDeserializerImpl(DefaultCredentialsProvider.builder().build(),
getConfigs());
byte[] recordWithSchemaHeaderBytes = new
byte[recordWithSchemaHeader.remaining()];

```

```

        recordWithSchemaHeader.get(recordWithSchemaHeaderBytes, 0,
recordWithSchemaHeaderBytes.length);
        com.amazonaws.services.schemaregistry.common.Schema awsSchema =
            glueSchemaRegistryDeserializer.getSchema(recordWithSchemaHeaderBytes);
        byte[] record =
glueSchemaRegistryDeserializer.getData(recordWithSchemaHeaderBytes);

        //The following lines serialize an AVRO schema record
        if (DataFormat.AVRO.name().equals(awsSchema.getDataFormat())) {
            Schema avroSchema = new
org.apache.avro.Schema.Parser().parse(awsSchema.getSchemaDefinition());
            Object genericRecord = convertBytesToRecord(avroSchema, record);
            System.out.println(genericRecord);
        }

```

Interaction avec les données à l'aide des Kinesis Data Streams APIs

Voici un exemple de code pour utiliser le PutRecords et GetRecords APIs.

```

//Full sample code
import
com.amazonaws.services.schemaregistry.deserializers.GlueSchemaRegistryDeserializerImpl;
import
com.amazonaws.services.schemaregistry.serializers.GlueSchemaRegistrySerializerImpl;
import com.amazonaws.services.schemaregistry.utils.AVROUtils;
import com.amazonaws.services.schemaregistry.utils.AWSSchemaRegistryConstants;
import org.apache.avro.Schema;
import org.apache.avro.generic.GenericData;
import org.apache.avro.generic.GenericDatumReader;
import org.apache.avro.generic.GenericDatumWriter;
import org.apache.avro.generic.GenericRecord;
import org.apache.avro.io.Decoder;
import org.apache.avro.io.DecoderFactory;
import org.apache.avro.io.Encoder;
import org.apache.avro.io.EncoderFactory;
import software.amazon.awssdk.auth.credentials.DefaultCredentialsProvider;
import software.amazon.awssdk.services.glue.model.DataFormat;

import java.io.ByteArrayOutputStream;
import java.io.File;
import java.io.IOException;
import java.nio.ByteBuffer;
import java.util.Collections;

```



```

import java.util.HashMap;
import java.util.Map;

public class PutAndGetExampleWithEncodedData {
    static final String regionName = "us-east-2";
    static final String streamName = "testStream1";
    static final String schemaName = "User-Topic";
    static final String AVRO_USER_SCHEMA_FILE = "src/main/resources/user.avsc";
    KinesisApi kinesisApi = new KinesisApi();

    void runSampleForPutRecord() throws IOException {
        Object testRecord = getTestRecord();
        byte[] recordAsBytes = convertRecordToBytes(testRecord);
        String schemaDefinition =
AVROUtils.getInstance().getSchemaDefinition(testRecord);

        //The following lines add a Schema Header to a record
        com.amazonaws.services.schemaregistry.common.Schema awsSchema =
            new com.amazonaws.services.schemaregistry.common.Schema(schemaDefinition,
DataFormat.AVRO.name(),
                schemaName);
        GlueSchemaRegistrySerializerImpl glueSchemaRegistrySerializer =
            new
GlueSchemaRegistrySerializerImpl(DefaultCredentialsProvider.builder().build(), new
GlueSchemaRegistryConfiguration(regionName));
        byte[] recordWithSchemaHeader =
            glueSchemaRegistrySerializer.encode(streamName, awsSchema, recordAsBytes);

        //Use PutRecords api to pass a list of records
        kinesisApi.putRecords(Collections.singletonList(recordWithSchemaHeader),
streamName, regionName);

        //OR
        //Use PutRecord api to pass single record
        //kinesisApi.putRecord(recordWithSchemaHeader, streamName, regionName);
    }

    byte[] runSampleForGetRecord() throws IOException {
        ByteBuffer recordWithSchemaHeader = kinesisApi.getRecords(streamName,
regionName);

        //The following lines remove the schema registry header
        GlueSchemaRegistryDeserializerImpl glueSchemaRegistryDeserializer =

```

```

        new
        GlueSchemaRegistryDeserializerImpl(DefaultCredentialsProvider.builder().build(), new
        GlueSchemaRegistryConfiguration(regionName));
        byte[] recordWithSchemaHeaderBytes = new
        byte[recordWithSchemaHeader.remaining()];
        recordWithSchemaHeader.get(recordWithSchemaHeaderBytes, 0,
        recordWithSchemaHeaderBytes.length);

        com.amazonaws.services.schemaregistry.common.Schema awsSchema =
            glueSchemaRegistryDeserializer.getSchema(recordWithSchemaHeaderBytes);

        byte[] record =
        glueSchemaRegistryDeserializer.getData(recordWithSchemaHeaderBytes);

        //The following lines serialize an AVRO schema record
        if (DataFormat.AVRO.name().equals(awsSchema.getDataFormat())) {
            Schema avroSchema = new
            org.apache.avro.Schema.Parser().parse(awsSchema.getSchemaDefinition());
            Object genericRecord = convertBytesToRecord(avroSchema, record);
            System.out.println(genericRecord);
        }

        return record;
    }

    private byte[] convertRecordToBytes(final Object record) throws IOException {
        ByteArrayOutputStream recordAsBytes = new ByteArrayOutputStream();
        Encoder encoder = EncoderFactory.get().directBinaryEncoder(recordAsBytes,
        null);
        GenericDatumWriter datumWriter = new
        GenericDatumWriter<>(AVROUtils.getInstance().getSchema(record));
        datumWriter.write(record, encoder);
        encoder.flush();
        return recordAsBytes.toByteArray();
    }

    private GenericRecord convertBytesToRecord(Schema avroSchema, byte[] record) throws
    IOException {
        final GenericDatumReader<GenericRecord> datumReader = new
        GenericDatumReader<>(avroSchema);
        Decoder decoder = DecoderFactory.get().binaryDecoder(record, null);
        GenericRecord genericRecord = datumReader.read(null, decoder);
        return genericRecord;
    }
}

```

```
private Map<String, String> getMetadata() {
    Map<String, String> metadata = new HashMap<>();
    metadata.put("event-source-1", "topic1");
    metadata.put("event-source-2", "topic2");
    metadata.put("event-source-3", "topic3");
    metadata.put("event-source-4", "topic4");
    metadata.put("event-source-5", "topic5");
    return metadata;
}

private GlueSchemaRegistryConfiguration getConfigs() {
    GlueSchemaRegistryConfiguration configs = new
GlueSchemaRegistryConfiguration(regionName);
    configs.setSchemaName(schemaName);
    configs.setAutoRegistration(true);
    configs.setMetadata(getMetadata());
    return configs;
}

private Object getTestRecord() throws IOException {
    GenericRecord genericRecord;
    Schema.Parser parser = new Schema.Parser();
    Schema avroSchema = parser.parse(new File(AVRO_USER_SCHEMA_FILE));

    genericRecord = new GenericData.Record(avroSchema);
    genericRecord.put("name", "testName");
    genericRecord.put("favorite_number", 99);
    genericRecord.put("favorite_color", "red");

    return genericRecord;
}
}
```

Cas d'utilisation : Amazon Managed Service pour Apache Flink

Apache Flink est un cadre open source populaire et un moteur de traitement distribué pour les calculs avec état sur des flux de données sans limite et limités. Amazon Managed Service pour Apache Flink est un AWS service entièrement géré qui vous permet de créer et de gérer des applications Apache Flink pour traiter des données de streaming.

Apache Flink open source fournit un certain nombre de sources et de récepteurs. Par exemple, les sources de données prédéfinies incluent la lecture à partir de fichiers, de répertoires et de sockets,

ainsi que l'ingestion de données à partir de collections et d'itérateurs. **DataStream** Les connecteurs Apache Flink fournissent du code permettant à Apache Flink de s'interfacer avec divers systèmes tiers, tels qu'Apache Kafka ou Kinesis en tant que sources et/ou récepteurs.

Pour plus d'informations, veuillez consulter le [Guide du développeur Amazon Kinesis Data Analytics](#).

Connecteur Kafka Apache Flink

Apache Flink fournit un connecteur de flux de données Apache Kafka pour lire et écrire des données sur des sujets Kafka avec des garanties en une seule fois. L'application consommateur Kafka de Flink, `FlinkKafkaConsumer`, permet d'accéder à la lecture d'une ou de plusieurs rubriques Kafka. L'application producteur kafka d'Apache Flink, `FlinkKafkaProducer`, permet d'écrire un flux d'enregistrements à une ou plusieurs rubriques Kafka. Pour de plus amples informations, veuillez consulter [Apache Kafka Connector](#).

Connecteur de flux Kinesis Apache Flink

Le connecteur de flux de données Kinesis vous permet d'accéder à Amazon Kinesis Data Streams. `FlinkKinesisConsumer` Il s'agit d'une source de données de streaming parallèle qui s'abonne à plusieurs flux Kinesis au sein d'une même région de AWS service et qui peut gérer de manière transparente le repartitionnement des flux pendant l'exécution de la tâche. Chaque sous-tâche de l'application consommateur est responsable de la récupération des enregistrements de données à partir de plusieurs partitions Kinesis. Le nombre de partitions récupérées par chaque sous-tâche change au fur et à mesure que les partitions sont fermées et créées par Kinesis. Le `FlinkKinesisProducer` utilise Kinesis Producer Library (KPL) pour placer les données d'un flux Apache Flink dans un flux Kinesis. Pour plus d'informations, veuillez consulter [Amazon Kinesis Streams Connector](#).

Pour de plus amples informations, veuillez consulter le [AWS Glue Référentiel Schema Github](#).

Intégration à Apache Flink

La SerDes bibliothèque fournie avec Schema Registry s'intègre à Apache Flink. Pour travailler avec Apache Flink, vous devez implémenter des interfaces [SerializationSchema](#) et [DeserializationSchema](#) appelées `GlueSchemaRegistryAvroSerializationSchema` et `GlueSchemaRegistryAvroDeserializationSchema`, que vous pouvez brancher sur des connecteurs Apache Flink.

Ajouter un AWS Glue Dépendance du registre de schéma dans l'application Apache Flink

Pour configurer les dépendances d'intégration pour AWS Glue Registre des schémas dans l'application Apache Flink :

1. Ajoutez la dépendance au fichier pom.xml.


```
<dependency>
  <groupId>software.amazon.glue</groupId>
  <artifactId>schema-registry-flink-serde</artifactId>
  <version>1.0.0</version>
</dependency>
```

Intégration de Kafka ou Amazon MSK à Apache Flink

Vous pouvez utiliser Service géré pour Apache Flink pour Apache Flink, avec Kafka comme source ou Kafka comme collecteur.


Kafka en tant que source

Le diagramme suivant illustre l'intégration de Kinesis Data Streams Kinesis à Service géré pour Apache Flink pour Apache Flink, avec Kafka en tant que source.



Kafka en tant que récepteur

Le diagramme suivant illustre l'intégration de Kinesis Data Streams Kinesis à Service géré pour Apache Flink pour Apache Flink, avec Kafka en tant que collecteur.



Pour intégrer Kafka (ou Amazon MSK) à Service géré pour Apache Flink pour Apache Flink, avec Kafka comme source ou Kafka comme collecteur, apportez les modifications de code ci-dessous. Ajoutez les blocs de code en gras à votre code respectif dans les sections analogues.

Si Kafka est la source, utilisez le code de désérialiseur (bloc 2). Si Kafka est le récepteur, utilisez le code de sérialiseur (bloc 3).

```

StreamExecutionEnvironment env = StreamExecutionEnvironment.getExecutionEnvironment();

String topic = "topic";
Properties properties = new Properties();
properties.setProperty("bootstrap.servers", "localhost:9092");
properties.setProperty("group.id", "test");

// block 1
Map<String, Object> configs = new HashMap<>();
configs.put(AWSSchemaRegistryConstants.AWS_REGION, "aws-region");
configs.put(AWSSchemaRegistryConstants.SCHEMA_AUTO_REGISTRATION_SETTING, true);
configs.put(AWSSchemaRegistryConstants.AVRO_RECORD_TYPE,
    AvroRecordType.GENERIC_RECORD.getName());

FlinkKafkaConsumer<GenericRecord> consumer = new FlinkKafkaConsumer<>(
    topic,
    // block 2
    GlueSchemaRegistryAvroDeserializationSchema.forGeneric(schema, configs),
    properties);

FlinkKafkaProducer<GenericRecord> producer = new FlinkKafkaProducer<>(

```

```
topic,
// block 3
GlueSchemaRegistryAvroSerializationSchema.forGeneric(schema, topic, configs),
properties);
```


```
DataStream<GenericRecord> stream = env.addSource(consumer);
stream.addSink(producer);
env.execute();
```

Intégration de Kinesis Data Streams à Apache Flink

Vous pouvez utiliser Service géré pour Apache Flink pour Apache Flink, avec Data Streams comme source ou comme collecteur.


Kinesis Data Streams en tant que source

Le diagramme suivant illustre l'intégration de Kinesis Data Streams Kinesis à Service géré pour Apache Flink pour Apache Flink, avec Kinesis Data Streams en tant que source.



Kinesis Data Streams en tant que récepteur

Le diagramme suivant illustre l'intégration de Kinesis Data Streams Kinesis à Service géré pour Apache Flink pour Apache Flink, avec Kinesis Data Streams en tant que collecteur.



Pour intégrer Kinesis Data Streams à Service géré pour Apache Flink pour Apache Flink, avec Kinesis Data Streams en tant que source ou Kinesis Data Streams en tant que collecteur, apportez les modifications de code ci-dessous. Ajoutez les blocs de code en gras à votre code respectif dans les sections analogues.

Si Kinesis Data Streams est la source, utilisez le code de désérialiseur (bloc 2). Si Kinesis Data Streams est le récepteur, utilisez le code de sérialiseur (bloc 3).

```
StreamExecutionEnvironment env = StreamExecutionEnvironment.getExecutionEnvironment();

String streamName = "stream";
Properties consumerConfig = new Properties();
consumerConfig.put(AWSConfigConstants.AWS_REGION, "aws-region");
consumerConfig.put(AWSConfigConstants.AWS_ACCESS_KEY_ID, "aws_access_key_id");
consumerConfig.put(AWSConfigConstants.AWS_SECRET_ACCESS_KEY, "aws_secret_access_key");
consumerConfig.put(ConsumerConfigConstants.STREAM_INITIAL_POSITION, "LATEST");

// block 1
Map<String, Object> configs = new HashMap<>();
configs.put(AWSSchemaRegistryConstants.AWS_REGION, "aws-region");
configs.put(AWSSchemaRegistryConstants.SCHEMA_AUTO_REGISTRATION_SETTING, true);
configs.put(AWSSchemaRegistryConstants.AVRO_RECORD_TYPE,
    AvroRecordType.GENERIC_RECORD.getName());

FlinkKinesisConsumer<GenericRecord> consumer = new FlinkKinesisConsumer<>(
    streamName,
    // block 2
    GlueSchemaRegistryAvroDeserializationSchema.forGeneric(schema, configs),
```



```
properties);

FlinkKinesisProducer<GenericRecord> producer = new FlinkKinesisProducer<>(
    // block 3
    GlueSchemaRegistryAvroSerializationSchema.forGeneric(schema, topic, configs),
    properties);
producer.setDefaultStream(streamName);
producer.setDefaultPartition("0");

DataStream<GenericRecord> stream = env.addSource(consumer);
stream.addSink(producer);
env.execute();
```

Cas d'utilisation : intégration avec AWS Lambda

Pour utiliser une AWS Lambda fonction en tant que consommateur Apache Kafka/Amazon MSK et désérialiser les messages codés en AVRO en utilisant AWS Glue Registre des schémas, visitez la [page MSK Labs](#).

Cas d'utilisation : AWS Glue Data Catalog

AWS Glue les tables supportent des schémas que vous pouvez spécifier manuellement ou par référence au AWS Glue Registre des schémas. Le registre de schémas s'intègre au catalogue de données pour vous permettre d'utiliser éventuellement les schémas stockés dans le registre de schémas lors de la création ou de la mise à jour AWS Glue tables ou partitions du catalogue de données. Pour identifier une définition de schéma dans le registre de schémas, vous devez au minimum connaître l'ARN du schéma dont il fait partie. Une version de schéma d'un schéma, qui contient une définition de schéma, peut être référencée par son UUID ou son numéro de version. Il y a toujours une version de schéma, la « dernière » version, qui peut être recherchée sans connaître son numéro de version ou son UUID.

Lors de l'appel des opérations CreateTable ou UpdateTable, vous transmettez une structure TableInput qui contient un StorageDescriptor, qui peut avoir une SchemaReference à un schéma existant dans le registre de schémas. De même, lorsque vous appelez le GetTable ou GetPartition APIs, la réponse peut contenir le schéma et le SchemaReference. Lorsqu'une table ou une partition a été créée à l'aide de références de schéma, le catalogue de données tente d'extraire le schéma pour cette référence de schéma. Dans le cas où il ne parvient pas à trouver le schéma dans le registre de schémas, il renvoie un schéma vide dans la réponse GetTable ; sinon la réponse aura à la fois le schéma et la référence du schéma.

Vous pouvez également effectuer les actions depuis le AWS Glue console.

Pour effectuer ces opérations et créer, mettre à jour ou afficher les informations de schéma, vous devez accorder un rôle IAM à l'appelant qui fournit les autorisations pour l'API `GetSchemaVersion`.

Ajout d'une table ou mise à jour du schéma pour une table

L'ajout d'une nouvelle table à partir d'un schéma existant lie la table à une version de schéma spécifique. Une fois les nouvelles versions du schéma enregistrées, vous pouvez mettre à jour cette définition de table à partir de la page Afficher la table du AWS Glue console ou à l'aide de l'[UpdateTable action \(Python : update_table\)API](#).

Ajout d'une table à partir d'un schéma existant

Vous pouvez créer un AWS Glue table à partir d'une version de schéma dans le registre à l'aide du AWS Glue console ou `CreateTable` API.

AWS Glue « Hello, World! »

Lors de l'appel de l'API `CreateTable`, vous transmettez une `TableInput` qui contient un `StorageDescriptor`, qui a une `SchemaReference` à un schéma existant dans le registre de schémas.

AWS Glue console

Pour créer un tableau à partir du AWS Glue console :

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous Data catalog (Catalogue de données), choisissez Tables.
3. Dans le menu Add tables (Ajouter des tables), choisissez Add table from existing schema (Ajouter une table à partir d'un schéma existant).
4. Configurez les propriétés de la table et le magasin de données conformément au AWS Glue .
5. Sur la page Choisir un schéma de Glue, sélectionnez le registre où réside le schéma.
6. Choisissez le nom du schéma et sélectionnez la version du schéma à appliquer.
7. Passez en revue la prévisualisation du schéma, puis choisissez Next (Suivant).
8. Vérifiez et créez la table.

Le schéma et la version appliqués à la table s'affichent dans la colonne Glue schema (Schéma Glue) dans la liste des tables. Vous pouvez afficher le tableau pour voir plus de détails.

Mise à jour du schéma pour une table

Lorsqu'une nouvelle version de schéma est disponible, vous souhaitez peut-être mettre à jour le schéma d'une table à l'aide de l'[UpdateTable action \(Python : update_table\)](#) API ou du AWS Glue console.

Important

Lors de la mise à jour du schéma d'une table existante dotée d'un AWS Glue schéma spécifié manuellement, le nouveau schéma référencé dans le registre des schémas peut être incompatible. Cela peut entraîner l'échec de vos tâches.

AWS Glue « Hello, World! »

Lors de l'appel de l'API UpdateTable, vous transmettez une TableInput qui contient un StorageDescriptor, qui a une SchemaReference à un schéma existant dans le registre de schémas.

AWS Glue console

Pour mettre à jour le schéma d'une table à partir du AWS Glue console :

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous Data catalog (Catalogue de données), choisissez Tables.
3. Affichez la table à partir de la liste des tables.
4. Cliquez sur Update schema (Mettre à jour le schéma) dans la zone qui vous informe d'une nouvelle version.
5. Examinez les différences entre le schéma actuel et le nouveau.
6. Choisissez Show all schema differences (Afficher toutes les différences du schéma) pour plus de détails.
7. Choisissez Save table (Enregistrer la table) pour accepter la nouvelle version.

Cas d'utilisation : AWS Glue streaming

AWS Glue le streaming consomme des données provenant de sources de streaming et effectue des opérations ETL avant d'écrire sur un récepteur de sortie. La source de streaming d'entrée peut être spécifiée à l'aide d'une table de données ou directement en spécifiant la configuration de la source.

AWS Glue le streaming prend en charge une table de catalogue de données pour la source de streaming créée avec le schéma présent dans AWS Glue Registre des schémas. Vous pouvez créer un schéma dans le AWS Glue Registre de schémas et création d'un AWS Glue table avec une source de streaming utilisant ce schéma. Cette AWS Glue le tableau peut être utilisé comme entrée dans un AWS Glue tâche de diffusion pour désérialiser les données dans le flux d'entrée.

Il convient de noter ici que le schéma du AWS Glue Modifications du registre des schémas, vous devez redémarrer le AWS Glue la tâche de streaming doit refléter les modifications apportées au schéma.

Cas d'utilisation : Apache Kafka Streams

L'API Apache Kafka Streams est une bibliothèque client pour le traitement et l'analyse des données stockées dans Apache Kafka. Cette section décrit l'intégration d'Apache Kafka Streams avec AWS Glue Schema Registry, qui vous permet de gérer et d'appliquer des schémas sur vos applications de streaming de données. Pour de plus amples informations sur Apache Kafka Streams, veuillez consulter [Apache Kafka Streams](#).

Intégration aux SerDes bibliothèques

Il existe une classe `GlueSchemaRegistryKafkaStreamsSerde` avec laquelle vous pouvez configurer une application Streams.

Exemple de code d'application Kafka Streams

Pour utiliser le plugin AWS Glue Registre de schémas dans une application Apache Kafka Streams :

1. Configurez l'application Kafka Streams.

```
final Properties props = new Properties();
props.put(StreamsConfig.APPLICATION_ID_CONFIG, "avro-streams");
props.put(StreamsConfig.BOOTSTRAP_SERVERS_CONFIG, "localhost:9092");
props.put(StreamsConfig.CACHE_MAX_BYTES_BUFFERING_CONFIG, 0);
props.put(StreamsConfig.DEFAULT_KEY_SERDE_CLASS_CONFIG,
Serdes.String().getClass().getName());
```

```
props.put(StreamsConfig.DEFAULT_VALUE_SERDE_CLASS_CONFIG,
AWSKafkaAvroSerDe.class.getName());
props.put(ConsumerConfig.AUTO_OFFSET_RESET_CONFIG, "earliest");

props.put(AWSSchemaRegistryConstants.AWS_REGION, "aws-region");
props.put(AWSSchemaRegistryConstants.SCHEMA_AUTO_REGISTRATION_SETTING, true);
props.put(AWSSchemaRegistryConstants.AVRO_RECORD_TYPE,
AvroRecordType.GENERIC_RECORD.getName());
props.put(AWSSchemaRegistryConstants.DATA_FORMAT, DataFormat.AVRO.name());
```

2. Créez un flux à partir de la rubrique avro-input.

```
StreamsBuilder builder = new StreamsBuilder();
final KStream<String, GenericRecord> source = builder.stream("avro-input");
```

3. Traitez les enregistrements de données (l'exemple filtre les enregistrements dont la valeur de favorite_color (couleur favorite) est pink (rose) ou dont la valeur de amount (montant) est 15).

```
final KStream<String, GenericRecord> result = source
    .filter((key, value) -
    > !"pink".equals(String.valueOf(value.get("favorite_color"))));
    .filter((key, value) -> !"15.0".equals(String.valueOf(value.get("amount"))));
```

4. Réécrivez les résultats dans la rubrique avro-output.

```
result.to("avro-output");
```

5. Démarrez l'application Apache Kafka Streams.

```
KafkaStreams streams = new KafkaStreams(builder.build(), props);
streams.start();
```

Résultats de l'implémentation

Ces résultats montrent le processus de filtrage des enregistrements qui ont été filtrés à l'étape 3 sous la forme d'une valeur favorite_color (couleur favorite) « pink » (rose) ou d'une valeur de « 15.0 ».

Enregistrements avant le filtrage :

```
{"name": "Sansa", "favorite_number": 99, "favorite_color": "white"}
{"name": "Harry", "favorite_number": 10, "favorite_color": "black"}
{"name": "Hermione", "favorite_number": 1, "favorite_color": "red"}
{"name": "Ron", "favorite_number": 0, "favorite_color": "pink"}
{"name": "Jay", "favorite_number": 0, "favorite_color": "pink"}

{"id": "commute_1", "amount": 3.5}
{"id": "grocery_1", "amount": 25.5}
{"id": "entertainment_1", "amount": 19.2}
{"id": "entertainment_2", "amount": 105}
{"id": "commute_1", "amount": 15}
```


Enregistrements après filtrage :

```
{"name": "Sansa", "favorite_number": 99, "favorite_color": "white"}
{"name": "Harry", "favorite_number": 10, "favorite_color": "black"}
{"name": "Hermione", "favorite_number": 1, "favorite_color": "red"}
{"name": "Ron", "favorite_number": 0, "favorite_color": "pink"}

{"id": "commute_1", "amount": 3.5}
{"id": "grocery_1", "amount": 25.5}
{"id": "entertainment_1", "amount": 19.2}
{"id": "entertainment_2", "amount": 105}
```

Cas d'utilisation : Apache Kafka Connect

L'intégration d'Apache Kafka Connect avec le AWS Glue Le registre des schémas vous permet d'obtenir des informations de schéma à partir de connecteurs. Les convertisseurs Apache Kafka spécifient le format des données dans Apache Kafka et comment les traduire en données Apache Kafka Connect. Chaque utilisateur d'Apache Kafka Connect devra configurer ces convertisseurs en fonction du format souhaité pour leurs données lorsqu'elles sont chargées depuis ou stockées dans Apache Kafka. De cette façon, vous pouvez définir vos propres convertisseurs pour traduire les données Apache Kafka Connect dans le type utilisé dans AWS Glue Schema Registry (par exemple : Avro) et utilisez notre sérialiseur pour enregistrer son schéma et effectuer la sérialisation. Ensuite, les convertisseurs peuvent également utiliser notre désérialiseur pour désérialiser les données reçues d'Apache Kafka et les convertir en données Apache Kafka Connect. Un exemple de diagramme de flux de travail est présenté ci-dessous.



1. Installez le aws-glue-schema-registry projet en clonant le dépôt [Github pour le AWS Glue Registre des schémas](#).

```
git clone git@github.com:aws-labs/aws-glue-schema-registry.git
cd aws-glue-schema-registry
mvn clean install
mvn dependency:copy-dependencies
```

2. Si vous prévoyez d'utiliser Apache Kafka Connect en mode autonome, mettez à jour connect-standalone.properties à l'aide des instructions suivantes pour cette étape. Si vous prévoyez d'utiliser Apache Kafka Connect en mode distribué, mettez à jour le connect-avro-distributedfichier .properties en suivant les mêmes instructions.

- a. Ajoutez également ces propriétés au fichier de propriétés de connexion Apache Kafka :

```
key.converter.region=aws-region
value.converter.region=aws-region
key.converter.schemaAutoRegistrationEnabled=true
value.converter.schemaAutoRegistrationEnabled=true
key.converter.avroRecordType=GENERIC_RECORD
value.converter.avroRecordType=GENERIC_RECORD
```

- b. Ajoutez la commande ci-dessous à la section Mode de lancement sous kafka-run-class.sh :

```
-cp $CLASSPATH:"<your AWS GlueSchema Registry base directory>/target/dependency/*"
```

3. Ajoutez la commande ci-dessous à la section Mode de lancement sous kafka-run-class.sh

```
-cp $CLASSPATH:"<your AWS GlueSchema Registry base directory>/target/dependency/*"
```

Elle doit ressembler à ce qui suit :

```
# Launch mode
if [ "$DAEMON_MODE" = "xtrue" ]; then
    nohup "$JAVA" $KAFKA_HEAP_OPTS $KAFKA_JVM_PERFORMANCE_OPTS $KAFKA_GC_LOG_OPTS
    $KAFKA_JMX_OPTS $KAFKA_LOG4J_OPTS -cp $CLASSPATH:"/Users/johndoe/aws-glue-schema-
    registry/target/dependency/*" $KAFKA_OPTS "$@" > "$CONSOLE_OUTPUT_FILE" 2>&1 < /dev/
    null &
else
    exec "$JAVA" $KAFKA_HEAP_OPTS $KAFKA_JVM_PERFORMANCE_OPTS $KAFKA_GC_LOG_OPTS
    $KAFKA_JMX_OPTS $KAFKA_LOG4J_OPTS -cp $CLASSPATH:"/Users/johndoe/aws-glue-schema-
    registry/target/dependency/*" $KAFKA_OPTS "$@"
fi
```

4. Si vous utilisez bash, exécutez les commandes ci-dessous pour configurer votre CLASSPATH dans votre bash_profile. Pour tout autre shell, mettez à jour l'environnement en conséquence.

```
echo 'export GSR_LIB_BASE_DIR=<>' >> ~/.bash_profile
echo 'export GSR_LIB_VERSION=1.0.0' >> ~/.bash_profile
echo 'export KAFKA_HOME=<your Apache Kafka installation directory>' >> ~/.bash_profile
echo 'export CLASSPATH=$CLASSPATH:$GSR_LIB_BASE_DIR/avro-kafkaconnect-converter/
target/schema-registry-kafkaconnect-converter-$GSR_LIB_VERSION.jar:$GSR_LIB_BASE_DIR/
common/target/schema-registry-common-$GSR_LIB_VERSION.jar:$GSR_LIB_BASE_DIR/
avro-serializer-deserializer/target/schema-registry-serde-$GSR_LIB_VERSION.jar'
>> ~/.bash_profile
source ~/.bash_profile
```

5. (Facultatif) Si vous souhaitez tester avec une source de fichier simple, clonez le connecteur de source de fichier.

```
git clone https://github.com/mmolimar/kafka-connect-fs.git
cd kafka-connect-fs/
```


- a. Sous la configuration du connecteur source, modifiez le format de données sur Avro, le lecteur de fichiers sur `AvroFileReader` et mettez à jour un exemple d'objet Avro à partir du chemin d'accès du fichier à partir duquel vous lisez. Par exemple :

```
vim config/kafka-connect-fs.properties
```

```
fs.uris=<path to a sample avro object>
policy.regex=^.*\.avro$
file_reader.class=com.github.mmolimar.kafka.connect.fs.file.reader.AvroFileReader
```

- b. Installez le connecteur source.

```
mvn clean package
echo "export CLASSPATH=\$CLASSPATH:\\"$(find target/ -type f -name '*.jar'| grep
'\-package' | tr '\n' ':')\\"" >> ~/.bash_profile
source ~/.bash_profile
```

- c. Mettez à jour les propriétés du récepteur sous *<your Apache Kafka installation directory>*/config/connect-file-sink.properties, mettez à jour le nom de rubrique et le nom de fichier de sortie.

```
file=<output file full path>
topics=<my topic>
```

6. Démarrez le connecteur source (dans cet exemple, il s'agit d'un connecteur source de fichier).

```
$KAFKA_HOME/bin/connect-standalone.sh $KAFKA_HOME/config/connect-standalone.properties config/kafka-connect-fs.properties
```

7. Exécutez le connecteur du récepteur (dans cet exemple, il s'agit d'un connecteur de récepteur de fichiers).

```
$KAFKA_HOME/bin/connect-standalone.sh $KAFKA_HOME/config/connect-standalone.properties $KAFKA_HOME/config/connect-file-sink.properties
```

Pour un exemple d'utilisation de Kafka Connect, regardez le script `run-local-tests.sh` situé dans le dossier `integration-tests` du [référentiel Github pour AWS Glue Registre des schémas](#).

Migration depuis un registre de schémas tiers vers AWS Glue Registre de schémas

La migration d'un registre de schémas tiers vers le AWS Glue Le registre de schémas dépend du registre de schémas tiers actuel et existant. S'il existe des enregistrements dans une rubrique Apache Kafka qui ont été envoyés à l'aide d'un registre de schémas tiers, les applications consommateur ont besoin du registre de schémas tiers pour désérialiser ces enregistrements. Le `AWSKafkaAvroDeserializer` permet de spécifier une classe de désérialiseur secondaire qui pointe vers le désérialiseur tiers et qui est utilisée pour désérialiser ces enregistrements.

Il existe deux critères pour le retrait d'un schéma tiers. Tout d'abord, le retrait ne peut avoir lieu qu'après que les enregistrements dans les rubriques Apache Kafka utilisant le registre de schéma tiers ne soient plus requis par et pour les applications consommateur. Deuxièmement, le retrait peut se produire suite au vieillissement des rubriques Apache Kafka, en fonction de la période de rétention spécifiée pour ces rubriques. Notez que si vous avez des sujets qui sont conservés à l'infini, vous pouvez toujours migrer vers le AWS Glue Registre de schémas, mais vous ne pourrez pas retirer le registre de schémas tiers. Pour contourner le problème, vous pouvez utiliser une application ou Mirror Maker 2 pour lire un extrait du sujet actuel et passer à un nouveau sujet avec le AWS Glue Registre des schémas.

Pour migrer d'un registre de schéma tiers vers le AWS Glue Registre des schémas :

1. Créez un registre dans le AWS Glue Schema Registry, ou utilisez le registre par défaut.
2. Arrêtez l'application consommateur. Modifiez-le pour inclure AWS Glue Schema Registry en tant que désérialiseur principal et le registre de schémas tiers en tant que secondaire.
 - Définissez les propriétés de l'application consommateur. Dans cet exemple, la valeur `secondary_deserializer` est définie sur un autre désérialiseur. Le comportement est le suivant : l'application consommateur récupère les enregistrements auprès d'Amazon MSK et essaie d'abord d'utiliser le `AWSKafkaAvroDeserializer`. S'il ne parvient pas à lire l'octet magique qui contient l'ID du schéma Avro pour le AWS Glue Schéma de registre de schéma, `AWSKafkaAvroDeserializer` puis essaie d'utiliser la classe de désérialiseur fournie dans le `secondary_deserializer`. Les propriétés spécifiques au désérialiseur secondaire doivent également être fournies dans les propriétés de l'application consommateur, telles que `schema_registry_url_config` et `specific_avro_reader_config`, comme indiqué ci-dessous.

```
consumerProps.setProperty(ConsumerConfig.KEY_DESERIALIZER_CLASS_CONFIG,
    StringDeserializer.class.getName());
```

```
consumerProps.setProperty(ConsumerConfig.VALUE_DESERIALIZER_CLASS_CONFIG,
    AWSKafkaAvroDeserializer.class.getName());
consumerProps.setProperty(AWSSchemaRegistryConstants.AWS_REGION,
    KafkaClickstreamConsumer.gsrRegion);
consumerProps.setProperty(AWSSchemaRegistryConstants.SECONDARY_DESERIALIZER,
    KafkaAvroDeserializer.class.getName());
consumerProps.setProperty(KafkaAvroDeserializerConfig.SCHEMA_REGISTRY_URL_CONFIG,
    "URL for third-party schema registry");
consumerProps.setProperty(KafkaAvroDeserializerConfig.SPECIFIC_AVRO_READER_CONFIG,
    "true");
```

3. Redémarrez l'application consommateur.

4. Arrêtez le producteur et orientez-le vers le AWS Glue Registre des schémas.

- a. Définissez les propriétés du producteur. Dans cet exemple, le producteur utilisera le registre par défaut et enregistrera automatiquement les versions de schéma.

```
producerProps.setProperty(ProducerConfig.KEY_SERIALIZER_CLASS_CONFIG,
    StringSerializer.class.getName());
producerProps.setProperty(ProducerConfig.VALUE_SERIALIZER_CLASS_CONFIG,
    AWSKafkaAvroSerializer.class.getName());
producerProps.setProperty(AWSSchemaRegistryConstants.AWS_REGION, "us-east-2");
producerProps.setProperty(AWSSchemaRegistryConstants.AVRO_RECORD_TYPE,
    AvroRecordType.SPECIFIC_RECORD.getName());
producerProps.setProperty(AWSSchemaRegistryConstants.SCHEMA_AUTO_REGISTRATION_SETTING,
    "true");
```

5. (Facultatif) Déplacez manuellement les schémas et versions de schéma existants du registre de schémas tiers actuel vers le AWS Glue Registre de schémas, soit dans le registre par défaut dans AWS Glue Registre de schémas ou vers un registre spécifique autre que celui par défaut dans AWS Glue Registre des schémas. Cela peut être fait en exportant des schémas à partir des registres de schémas tiers au format JSON et en créant de nouveaux schémas dans AWS Glue Registre de schémas utilisant le AWS Management Console ou le AWS CLI.

Cette étape peut être importante si vous devez activer les contrôles de compatibilité avec les versions de schéma précédentes pour les versions de schéma nouvellement créées à l'aide du AWS CLI et AWS Management Console, ou lorsque les producteurs envoient des messages avec un nouveau schéma avec l'enregistrement automatique des versions de schéma activé.

6. Démarrez l'application producteur.

Connexion aux données

Une AWS Glue connexion est un objet de catalogue de données qui stocke les informations d'identification de connexion, les chaînes d'URI, les informations du cloud privé virtuel (VPC), etc. pour un magasin de données spécifique. AWS Glue les robots d'exploration, les jobs et les terminaux de développement utilisent des connexions pour accéder à certains types de magasins de données. Vous pouvez utiliser des connexions pour les sources et les cibles, mais aussi réutiliser la même connexion pour plusieurs tâches de crawler ou extraction, transformation et chargement (ETL).

La dernière version du schéma de AWS Glue connexions fournit un moyen unifié de gérer les connexions de données entre les AWS services et les applications, tels que AWS Glue Amazon Athena, et Amazon SageMaker AI Unified Studio.

Présentation de l'utilisation des connecteurs et des connexions

Une connexion contient les propriétés requises pour se connecter à un magasin de données particulier. Lorsque vous créez une connexion, elle est stockée dans AWS Glue Data Catalog. Vous sélectionnez un connecteur, puis créez une connexion basée sur celui-ci.

Vous pouvez vous abonner à des connecteurs pour les magasins de données non pris en charge de manière native AWS Marketplace, puis utiliser ces connecteurs lorsque vous créez des connexions. Les développeurs peuvent également créer leurs propres connecteurs et vous pouvez les utiliser lors de la création de connexions.

Note

Les connexions créées à l'aide de AWS Marketplace connecteurs personnalisés ou de connecteurs AWS Glue Studio apparaissent dans la AWS Glue console avec le type défini sur UNKNOWN.

Les étapes suivantes décrivent le processus global d'utilisation des connecteurs dans AWS Glue Studio :

1. Abonnez-vous à un connecteur dans AWS Marketplace, ou développez votre propre connecteur et téléchargez-le sur AWS Glue Studio. Pour de plus amples informations, veuillez consulter [Ajouter des connecteurs à AWS Glue Studio](#).

2. Vérifiez les informations d'utilisation du connecteur. Vous pouvez trouver ces informations sous l'onglet Usage (Utilisation) de la page produit du connecteur. Par exemple, si vous cliquez sur l'onglet Utilisation de cette page produit, [AWS Glue Connector for Google BigQuery](#), vous pouvez voir dans la section Ressources supplémentaires un lien vers un blog sur l'utilisation de ce connecteur.
3. Créez une connexion. Vous sélectionnez le connecteur à utiliser et fournissez des informations supplémentaires pour la connexion, telles que les informations d'identification de connexion, les chaînes d'URI et les informations de Virtual Private Cloud (VPC). Pour de plus amples informations, veuillez consulter [Création de connexions pour les connecteurs](#).
4. Créez un rôle IAM pour votre tâche. La tâche dispose des autorisations du rôle IAM que vous spécifiez quand vous la créez. Ce rôle IAM doit disposer des autorisations nécessaires pour s'authentifier, extraire des données et écrire des données dans vos magasins de données.
5. Créez une tâche ETL et configurez les propriétés de la source de données pour cette tâche. Fournissez les options de connexion et les informations d'authentification comme indiqué par le fournisseur de connecteur personnalisé. Pour de plus amples informations, veuillez consulter [Création de tâches avec des connecteurs personnalisés](#).
6. Personnalisez votre tâche ETL en ajoutant des transformations ou des magasins de données supplémentaires, comme décrit dans [Démarrage de tâches Visual ETL dans AWS Glue Studio](#).
7. Si vous utilisez un connecteur pour la cible de données, configurez les propriétés de la cible de données pour votre tâche ETL. Fournissez les options de connexion et les informations d'authentification comme indiqué par le fournisseur de connecteur personnalisé. Pour de plus amples informations, veuillez consulter [the section called “Création de tâches avec des connecteurs personnalisés”](#).
8. Personnalisez l'environnement d'exécution de la tâche en configurant ses propriétés, comme décrit dans [Modifier les propriétés de tâche](#).
9. Exécutez la tâche.

Connexions unifiées

AWS a récemment introduit une nouvelle fonctionnalité appelée « SageMaker LakeHouse Connexions » ou « Connexions AWS Glue unifiées ». Cette fonctionnalité vous permet de créer des connexions qui peuvent être utilisées par plusieurs AWS services, tels que AWS Glue et Amazon Athena. Lorsque vous créez une source de données dans Amazon Athena, vous remarquerez une section qui fait référence aux entrées de AWS Glue connexion. Dans ce cas, il Amazon Athena

créera une AWS Glue connexion pour vous, y compris toutes les propriétés Amazon Athena spécifiques dans la section `AthenaProperties` de la connexion.

En revanche, si vous créez une connexion directement dans Apache Spark AWS Glue, vous serez uniquement invité à saisir les propriétés spécifiques à AWS Glue Apache Spark, qui seront stockées dans les sections `ConnectionProperties` et `SparkProperties` de la connexion.

Ces deux scénarios aboutissent à la création d'une « connexion unifiée », mais les connexions créées dans ne Amazon Athena sont configurées que pour une utilisation interne Amazon Athena, tandis que les connexions créées dans ne AWS Glue sont configurées que pour une utilisation interne AWS Glue. Cependant, il est possible de mettre à jour ces connexions avec les propriétés manquantes (propriétés Spark Amazon Athena ou propriétés Spark) afin qu'elles puissent être utilisées par les deux services. Amazon SageMaker AI Unified Studio s'en charge automatiquement en renseignant toutes les propriétés nécessaires (`ConnectionProperties`, `AthenaProperties` et `SparkProperties`) sur la AWS Glue connexion, en veillant à ce que la connexion puisse être utilisée par AWS Glue les deux Amazon Athena.

Il est important de noter que même si nous les appelons « connexions unifiées », les connexions créées dans AWS Glue ou Amazon Athena individuellement ne sont pas réellement unifiées à moins qu'elles ne soient correctement configurées pour être utilisées par les deux services. Seules les connexions créées via SageMaker Unified Studio sont réellement unifiées et utilisables par plusieurs services prêts à l'emploi.

En outre, les connexions créées dans ne AWS Glue sont pas visibles dans Amazon Athena car Amazon Athena affiche les sources de données, qui incluent une référence à une AWS Glue connexion mais ne sont pas la AWS Glue connexion elle-même. De même, les connexions créées dans ne Amazon Athena sont pas visibles dans AWS Glue Studio car AWS Glue Studio les connexions qui n'ont pas été configurées avec les paramètres nécessaires pour sont filtrées AWS Glue.

AWS Glue Studio crée des connexions unifiées par défaut. Dans la AWS Glue console, vous pouvez voir la version de la connexion dans le tableau des connexions sur la page des connexions, sur la page de détail des connexions, et le tableau des connexions sur la page des détails de la tâche.

La version de connexion est visible dans Détails de la connexion :

Postgresql connection v2

Edit

Delete

Create job

Connection details

Info

Connector type	POSTGRESQL	Require SSL connection	-
Subnet	subnet-	Security groups	sg-0
Description	-	Created on	2024-11-24 13:23:03.414000
Last modified	2024-11-24 13:23:03.414000	Version	2
Database	test	Host name	
Port	5432		

La version de connexion est également visible lorsque vous consultez toutes vos connexions.

Connections (323) Info

Actions ▼

Create connection

Create job

You can manage your connections or use a connection in a job.

🔍

Filter connections by property

<

1

2

3

4

5

6

7

...

33

>

	Name ▼	Status ▼	Type ▼	Last modified ▼	Version
☐	Opensearch connection v21125	✔ Ready	OpenSearch Service	Nov 25, 2024	2
☐	Mysql connectionfasdfasdfasdfsda	✔ Ready	JDBC	Nov 25, 2024	1
☐	redshift-only-athena	✔ Ready	REDSHIFT	Nov 25, 2024	2
☐	Oracle connection mordeche test 11-25	✘ Failed	ORACLE	Nov 25, 2024	2
☐	Oracle connection -	✘ Failed	ORACLE	Nov 25, 2024	2
☐	Redshift connection 123	✘ Failed	REDSHIFT	Nov 25, 2024	2
☐	Mysql connection sql test aurora v2	✘ Failed	MYSQL	Nov 24, 2024	2
☐	Postgresql connection v2	✘ Failed	POSTGRESQL	Nov 24, 2024	2
☐	Oracle connection	✔ Ready	JDBC	Nov 24, 2024	1
☐	Redshift connection 123e	✔ Ready	JDBC	Nov 24, 2024	1

Enfin, la version de connexion est visible dans l'onglet Détails du job pour un job.

Connections

Additional network connections [Info](#)

Choose a VPC configuration to access Amazon S3 data sources located in your virtual private cloud (VPC). You can create and manage Network connections in [AWS Glue](#). [↗](#)

None ▼

↻

Current connections

These are the connections currently associated with the job.

Name	Type	VPC	Subnet	Security Groups	Version
No connections					
No connections attached.					

Avec les connexions de version 2, vous disposez des fonctionnalités de connectivité de données étendues suivantes :

- **Découverte du type de connexion** : Support pour la création de connexions à l'aide de modèles standardisés. AWS Glue découvre automatiquement les types de connexion auxquels vous avez accès ainsi que les entrées requises et facultatives pour un type de connexion donné.
- **Réutilisabilité** : définitions de connexion réutilisables sur tous les moteurs et outils de traitement des AWS données tels que AWS Glue Amazon Athena, et Amazon SageMaker AI. Les connexions contiennent désormais AthenaProperties SparkProperties, PythonProperties qui permettent de spécifier des propriétés de connexion spécifiques à l'environnement/au service de calcul en plus des propriétés communes stockées dans ConnectionProperties. Athena crée désormais des connexions en AWS Glue spécifiant des propriétés spécifiques à Athéna dans le plan des propriétés. AthenaProperties
- **Aperçu des données** : possibilité de parcourir les métadonnées et de prévisualiser les données provenant de sources connectées.
- **Métadonnées du connecteur** : des connexions réutilisables peuvent être utilisées pour découvrir les métadonnées des tables.
- **Secrets liés au service** : les utilisateurs peuvent fournir les informations d'authentification nécessaires OAuth, de base ou personnalisées dans la CreateConnection demande. L' CreateConnection API crée un secret lié au service dans votre compte et stocke les informations d'identification en votre nom.

Types d'authentification pris en charge

Les connexions unifiées prennent en charge les types d'authentification suivants :

- **BASIC** — La plupart des types de connexion à la base de données et les types de AWS Glue connexion existants prennent en charge l'authentification de base, qui consiste en un nom d'utilisateur et un mot de passe. Auparavant, le nom des clés SecretsManager était spécifique au connecteur et, par exemple, pouvait être user, username, UserName, opensearch.net.http.auth.user, etc. C'est là que les connexions unifiées ont normalisé les types de connexion d'authentification de base sur les clés USERNAME et PASSWORD.
- **OAuth2** — La majorité des nouveaux types de connexion SaaS prennent en charge OAuth2 le protocole.
- **PERSONNALISÉ** — Certains types de connexion disposent d'un autre mécanisme d'authentification, tel que Google, BigQuery où les utilisateurs sont tenus de fournir le JSON qu'ils obtiennent de Google BigQuery.

Considérations

Lorsque vous créez une connexion unifiée pour les sources de données, tenez compte des différences suivantes :

- Lors de la création d'une connexion unifiée via AWS Glue Studio, les informations d'identification de l'utilisateur sont stockées au AWS Secrets Manager lieu de la connexion elle-même. Cela signifie que les jobs doivent désormais accéder à Secrets Manager.
- Si les tâches sont exécutées dans un VPC, elles nécessitent soit un point de terminaison VPC, soit une passerelle NAT pour y accéder, AWS Secrets Manager ainsi que le Secure Token Service (STS), ce qui entraîne des coûts supplémentaires.
- Pour certaines sources de données (Redshift, SQL Server, MySQL, Oracle, PostgreSQL), la création d'une connexion unifiée via nécessite l'accès à et. AWS Glue Studio AWS STS AWS Secrets Manager Cela est nécessaire pour établir une connexion sécurisée et récupérer les informations d'identification requises pour accéder à ces sources de données au sein de votre Virtual Private Cloud (VPC).
- La création d'une connexion unifiée via AWS Glue Studio nécessite un rôle IAM autorisé à accéder aux ressources VPC AWS Secrets Manager et à les gérer (si vous utilisez un VPC) :
 - responsable des secrets : GetSecretValue
 - responsable des secrets : PutSecretValue
 - responsable des secrets : DescribeSecret
 - EC2 : CreateNetworkInterface
 - EC2 : DeleteNetworkInterface
 - EC2 : DescribeNetworkInterfaces
 - EC2 : DescribeSubnets

Connexions disponibles

AWS Glue prend en charge les types de connexion suivants :

- Adobe Analytics
- Adobe Marketo Engage
- Amazon Aurora (pris en charge si le pilote JDBC natif est utilisé. (Toutes les fonctionnalités du pilote ne peuvent pas être exploitées)

- Amazon DocumentDB
- Amazon DynamoDB
- Amazon OpenSearch Service, à utiliser avec AWS Glue for Spark.
- Amazon Redshift
- Asana
- Azure Cosmos, pour l'utilisation d'Azure Cosmos DB pour NoSQL avec AWS Glue des tâches ETL
- Azure SQL, à utiliser avec AWS Glue for Spark.
- Blackbaud
- CircleCI
- Datadog
- Moniteur DocuSign
- Domo
- Dynatrace
- Facebook Ads
- Facebook Page Insights
- Freshdesk
- Ventes de produits frais
- Google Ads
- Google Analytics 4
- Google BigQuery, à utiliser avec AWS Glue for Spark.
- Google Search Console
- Google Sheets
- HubSpot
- Instagram Ads
- Intercom
- JDBC
- Jira Cloud
- Kafka
- Kustomer

- LinkedIn
- Mailchimp
- Microsoft Teams
- Mixpanel
- Lundi
- MongoDB
- Atlas MongoDB
- Okta
- Oracle NetSuite
- Paypal
- Pendo
- Tuyauterie
- Carton de produits
- QuickBooks
- Salesforce
- Cloud de commerce Salesforce
- Salesforce Marketing Cloud
- Engagement avec le compte Salesforce Marketing Cloud (anciennement Salesforce Pardot)
- SAP HANA, à utiliser avec AWS Glue for Spark.
- SAP OData
- SendGrid
- ServiceNow
- Slack
- Smartsheet
- Snapchat Ads
- Stripe
- Snowflake, à utiliser avec AWS Glue for Spark.
- Teradata Vantage, lors de l'utilisation AWS Glue pour Spark.
- Twilio
- Vertica, à utiliser avec AWS Glue for Spark.

- WooCommerce
- Zendesk
- Zoho CRM
- Zoom Meetings
- Diverses offres Amazon Relational Database Service (Amazon RDS).
- Réseau (désigne une connexion à une source de données qui se trouve dans un Amazon Virtual Private Cloud (Amazon VPC))

Avec AWS Glue Studio, vous pouvez également créer une connexion pour un connecteur. Un connecteur est un package de code facultatif qui facilite l'accès aux magasins de données dans AWS Glue Studio. Pour de plus amples informations, veuillez consulter [Utilisation des connecteurs et des connexions avec AWS Glue Studio](#)

Pour plus d'informations sur la connexion aux bases de données locales, consultez [Comment accéder aux magasins de données sur site et les analyser AWS Glue à l'aide](#) du site Web AWS Big Data Blog.

Pour créer une connexion avec une configuration VPC tout en utilisant un rôle IAM personnalisé, celui-ci doit disposer des actions d'accès VPC suivantes :

- responsable des secrets : GetSecretValue
- responsable des secrets : PutSecretValue
- responsable des secrets : DescribeSecret
- EC2 : CreateNetworkInterface
- EC2 : DeleteNetworkInterface
- EC2 : DescribeNetworkInterfaces
- EC2 : DescribeSubnets

Limites

- Vous ne pouvez pas modifier les connexions via la AWS Glue console si vous avez créé une connexion v2 en utilisant AWS Glue APIs :
 - Amazon DocumentDB
 - Amazon Aurora

- MariaDB
- Atlas MongoDB
- MongoDB

AWS Glue propriétés de connexion

Cette rubrique contient des informations sur les propriétés des AWS Glue connexions.

Rubriques

- [Propriétés de connexion requises](#)
- [AWS Glue Propriétés de connexion JDBC](#)
- [AWS Glue Propriétés de connexion MongoDB et MongoDB Atlas](#)
- [Propriétés de connexion Salesforce](#)
- [Connexion Snowflake](#)
- [Connexion Vertica](#)
- [Connexion SAP HANA](#)
- [Connexion Azure SQL](#)
- [Connexion Teradata Vantage](#)
- [OpenSearch Connexion au service](#)
- [Connexion Azure Cosmos](#)
- [AWS Glue Propriétés de connexion SSL](#)
- [Propriétés de connexion Apache Kafka pour l'authentification du client](#)
- [BigQuery Connexion à Google](#)
- [Connexion Vertica](#)

Propriétés de connexion requises

Lorsque vous définissez une connexion sur la AWS Glue console, vous devez fournir des valeurs pour les propriétés suivantes :

Nom de la connexion

Saisissez un nom unique pour votre connexion.

Type de connexion

Choisissez JDBC ou l'un des types de connexion spécifiques.

Pour plus d'informations sur le type de connexion JDBC, consultez [the section called “Propriétés de connexion JDBC”](#)

Choisissez Network (Réseau) pour vous connecter à une source de données dans un environnement Amazon Virtual Private Cloud (Amazon VPC).

Selon le type que vous choisissez, la console AWS Glue affiche d'autres champs obligatoires. Par exemple, si vous choisissez Amazon RDS, vous devez ensuite choisir le moteur de base de données.

Require SSL connection (Connexion SSL obligatoire)

Lorsque vous sélectionnez cette option, vous AWS Glue devez vérifier que la connexion au magasin de données est connectée via un protocole SSL (Secure Sockets Layer) approuvé.

Pour plus d'informations, y compris les options supplémentaires disponibles lorsque vous sélectionnez cette option, consultez [the section called “Propriétés de connexion SSL”](#).

Sélectionner un cluster MSK (Amazon Managed Streaming for Apache Kafka (MSK) uniquement)

Spécifie un cluster MSK provenant d'un autre AWS compte.

Serveur bootstrap Kafka URLs (Kafka uniquement)

Spécifie une liste de serveurs bootstrap séparés par des virgules. URLs Incluez le numéro de port. Par exemple : b-1.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094, b-2.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094, b-3.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094

AWS Glue Propriétés de connexion JDBC

AWS Glue Studio crée désormais des connexions unifiées pour les sources de données MySQL, Oracle, PostgreSQL, Redshift et SQL Server, ce qui nécessite des étapes supplémentaires pour accéder aux ressources de Secrets Manager et VPC, ce qui peut entraîner des coûts supplémentaires. Vous pouvez accéder à ces connexions en AWS Glue Studio choisissant le nom de la connexion correspondante.

Pour de plus amples informations, veuillez consulter [Considérations](#).

AWS Glue peut se connecter aux magasins de données suivants via une connexion JDBC :

- Amazon Redshift
- Amazon Aurora
- Microsoft SQL Server
- MySQL
- Oracle
- PostgreSQL
- Flocon de neige, lorsque vous utilisez AWS Glue des chenilles.
- Aurora (pris en charge si le pilote JDBC natif est utilisé ; l'exploitation de toutes les fonctionnalités du pilote n'est pas possible)
- Amazon RDS for MariaDB

Important

Actuellement, une tâche ETL peut utiliser des connexions JDBC dans un seul sous-réseau. Si vous avez plusieurs magasins de données dans une tâche, ils doivent être sur le même sous-réseau ou accessibles depuis le sous-réseau.

Si vous choisissez d'utiliser vos propres versions de pilotes JDBC pour les robots d' AWS Glue exploration, ceux-ci consommeront des ressources dans les tâches et AWS Glue Amazon S3 pour s'assurer que les pilotes que vous avez fournis sont exécutés dans votre environnement. L'utilisation supplémentaire des ressources sera reflétée sur votre compte. De plus, le fait de fournir votre propre pilote JDBC ne signifie pas que le Crawler est capable de tirer parti de toutes les fonctionnalités du pilote. Les pilotes sont limités aux propriétés décrites dans [Defining connections in the Data Catalog](#).

Voici des propriétés supplémentaires pour le type de connexion JDBC.

URL JDBC

Saisissez l'URL de votre magasin de données JDBC. Pour la plupart des moteurs de base de données, ce champ est au format suivant. Dans ce format, remplacez *protocol*, *host*, *port*, et *db_name* par vos propres informations.

`jdbc:protocol://host:port/db_name`

En fonction du moteur de base de données, un autre format d'URL JDBC peut être requis. Ce format peut avoir une utilisation légèrement différente des deux-points (:) et de la barre oblique (/), ou des mots-clés différents pour spécifier les bases de données.

Pour que JDBC se connecte au magasin de données, un `db_name` dans le magasin de données est obligatoire. Le `db_name` permet d'établir une connexion réseau avec les `username` et `password` fournis. Une fois connecté, AWS Glue vous pouvez accéder à d'autres bases de données du magasin de données pour exécuter un robot d'exploration ou une tâche ETL.

Les exemples d'URL JDBC suivants montrent la syntaxe pour plusieurs moteurs de base de données.

- Pour se connecter au magasin de données d'un cluster Amazon Redshift avec une base de données `dev` :

```
jdbc:redshift://xxx.us-east-1.redshift.amazonaws.com:8192/dev
```

- Pour se connecter à un magasin de données Amazon RDS for MySQL avec une base de données `employee` :

```
jdbc:mysql://xxx-cluster.cluster-xxx.us-east-1.rds.amazonaws.com:3306/  
employee
```

- Pour se connecter à un magasin de données Amazon RDS for PostgreSQL avec une base de données `employee` :

```
jdbc:postgresql://xxx-cluster.cluster-xxx.us-  
east-1.rds.amazonaws.com:5432/employee
```

- Pour se connecter à un magasin de données Amazon RDS for Oracle avec un nom de service `employee` :

```
jdbc:oracle:thin://@xxx-cluster.cluster-xxx.us-  
east-1.rds.amazonaws.com:1521/employee
```

La syntaxe d'Amazon RDS for Oracle peut suivre les modèles suivants. Dans ces modèles, remplacez *hostport*, *service_name*, et *SID* par vos propres informations.

- `jdbc:oracle:thin://@host:port/service_name`
- `jdbc:oracle:thin://@host:port:SID`
- Pour se connecter à un magasin de données Amazon RDS for Microsoft SQL Server avec une base de données `employee` :

```
jdbc:sqlserver://xxx-cluster.cluster-xxx.us-east-1.rds.amazonaws.com:1433;databaseName=employee
```

La syntaxe d'Amazon RDS for SQL Server peut suivre les modèles suivants. Dans ces modèles, remplacez *server_nameport*, et *db_name* par vos propres informations.

- `jdbc:sqlserver://server_name:port;database=db_name`
- `jdbc:sqlserver://server_name:port;databaseName=db_name`
- Pour vous connecter à une Amazon Aurora PostgreSQL instance de la employee base de données, spécifiez le point de terminaison de l'instance de base de données, le port et le nom de la base de données :

```
jdbc:postgresql://employee_instance_1.aaaaaaaaaaaa.us-east-2.rds.amazonaws.com:5432/employee
```

- Pour vous connecter à un magasin de Amazon RDS for MariaDB données avec une employee base de données, spécifiez le point de terminaison de l'instance de base de données, le port et le nom de la base de données :

```
jdbc:mysql://xxx-cluster.cluster-xxx.aws-region.rds.amazonaws.com:3306/employee
```

 Warning

Les connexions JDBC Snowflake ne sont prises en charge que par les robots d'exploration. AWS Glue Lorsque vous utilisez le connecteur Snowflake dans des AWS Glue tâches, utilisez le type de connexion Snowflake.

Pour vous connecter à une l'instance Snowflake de la base de données sample, spécifiez le point de terminaison de l'instance Snowflake, l'utilisateur, le nom de base de données et le nom de rôle. Vous pouvez également ajouter le paramètre warehouse.

```
jdbc:snowflake://account_name.snowflakecomputing.com/?  
user=user_name&db=sample&role=role_name&warehouse=warehouse_name
```

 Important

Pour les connexions Snowflake via JDBC, l'ordre des paramètres dans l'URL est imposé et doit être le suivant : user, db, role_name et warehouse.

- Pour vous connecter à une instance Snowflake de la sample base de données via un lien AWS privé, spécifiez l'URL JDBC Snowflake comme suit :

```
jdbc:snowflake://account_name.region.privatelink.snowflakecomputing.com/?  
user=user_name&db=sample&role=role_name&warehouse=warehouse_name
```

Nom d'utilisateur

 Note

Nous vous recommandons d'utiliser un AWS secret pour stocker les informations de connexion au lieu de fournir directement votre nom d'utilisateur et votre mot de passe. Pour de plus amples informations, veuillez consulter [Stockage des informations de connexion dans AWS Secrets Manager](#).

Fournissez un nom d'utilisateur qui est autorisé à accéder au magasin de données JDBC.

Mot de passe

Saisissez le mot de passe pour le nom d'utilisateur qui a l'autorisation d'accès au magasin de données JDBC.

Port

Saisissez le port utilisé dans l'URL JDBC pour vous connecter à une instance Amazon RDS Oracle. Ce champ est uniquement affiché lorsque Require SSL connection (Connexion SSL obligatoire) est sélectionné pour une instance Amazon RDS Oracle.

VPC

Choisissez le nom du cloud privé virtuel (VPC) qui contient votre magasin de données. La AWS Glue console répertorie tout VPCs pour la région actuelle.

⚠ Important

Lorsque vous travaillez sur une connexion JDBC hébergée hors de AWS, par exemple avec des données provenant de Snowflake, votre VPC doit disposer d'une passerelle NAT qui divise le trafic en sous-réseaux publics et privés. Le sous-réseau public est utilisé pour la connexion à la source externe, et le sous-réseau interne est utilisé pour le traitement par. AWS Glue Pour plus d'informations sur la configuration de votre Amazon VPC pour les connexions externes, consultez [Connectez-vous à Internet ou à d'autres réseaux à l'aide de périphériques NAT](#) et [Configuration d'Amazon VPC pour les connexions JDBC aux magasins de données Amazon RDS à partir de AWS Glue](#).

Sous-réseau

Choisissez le sous-réseau du VPC qui contient votre magasin de données. La console AWS Glue répertorie tous les sous-réseaux pour le magasin de données de votre VPC.

Groupes de sécurité

Choisissez les groupes de sécurité associés à votre banque de données. AWS Glue nécessite un ou plusieurs groupes de sécurité dotés d'une règle de source entrante qui permet de se AWS Glue connecter. La AWS Glue console répertorie tous les groupes de sécurité auxquels un accès entrant est accordé à votre VPC. AWS Glue associe ces groupes de sécurité à l'interface elastic network attachée à votre sous-réseau VPC.

Nom de la classe de pilote JDBC (facultatif)

Indiquez le nom de classe de pilote JDBC personnalisé :

- Postgres : org.postgresql.Driver
- MySQL : com.mysql.jdbc.Driver, com.mysql.cj.jdbc.Driver
- Redshift : com.amazon.redshift.jdbc.Driver, com.amazon.redshift.jdbc42.Driver
- Oracle : oracle.jdbc.driver.OracleDriver
- SQL Server : com.microsoft.sqlserver.jdbc.SQLServerChauffeur

Chemin S3 du pilote JDBC (facultatif)

Indiquez l'emplacement Amazon S3 au pilote JDBC personnalisé. Il s'agit d'un chemin absolu vers un fichier .jar. Si vous souhaitez fournir vos propres pilotes JDBC afin de vous connecter à vos sources de données pour vos bases de données prises en charge par un Crawler, vous pouvez spécifier des valeurs pour les paramètres `customJdbcDriverS3Path` et `customJdbcDriverClassName`.

L'utilisation d'un pilote JDBC fourni par un client est limitée au [Propriétés de connexion requises](#) nécessaire.

AWS Glue Propriétés de connexion MongoDB et MongoDB Atlas

Voici des propriétés supplémentaires pour le type de connexion MongoDB ou MongoDB Atlas.

URL MongoDB

Saisissez l'URL de votre magasin de données MongoDB ou MongoDB Atlas :

- Pour MongoDB : `mongodb://host:port/database`. L'hôte peut être un nom d'hôte, une adresse IP ou un socket de domaine UNIX. Si la chaîne de connexion ne spécifie aucun port, elle utilise le port MongoDB par défaut, 27017.
- Pour MongoDB Atlas : `mongodb+srv://server.example.com/database`. L'hôte peut être un nom d'hôte qui suit et correspond à un enregistrement DNS SRV. Le format SRV ne nécessite pas de port et utilisera le port MongoDB par défaut, 27017.

Nom d'utilisateur

Note

Nous vous recommandons d'utiliser un AWS secret pour stocker les informations de connexion au lieu de fournir directement votre nom d'utilisateur et votre mot de passe. Pour de plus amples informations, veuillez consulter [Stockage des informations de connexion dans AWS Secrets Manager](#).

Fournissez un nom d'utilisateur qui est autorisé à accéder au magasin de données JDBC.

Mot de passe

Saisissez le mot de passe pour le nom d'utilisateur qui a l'autorisation d'accès au magasin de données MongoDB ou MongoDB Atlas.

Propriétés de connexion Salesforce

Vous trouverez ci-dessous des propriétés supplémentaires pour le type de connexion Salesforce.

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Salesforce.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Salesforce Rest que vous souhaitez utiliser.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.
- **IMPORT_DELETED_RECORDS**(String) - Par défaut : FALSE. Utilisé pour lire. Pour obtenir les enregistrements supprimés lors de la requête.
- **WRITE_OPERATION**(String) - Par défaut : INSERT. Utilisé pour écrire. La valeur doit être INSERT, UPDATE, UPSERT, DELETE.
- **ID_FIELD_NAMES**(String) - Valeur par défaut : null. Utilisé uniquement pour UPSERT.

Connexion Snowflake

Les propriétés suivantes sont utilisées pour configurer une connexion Snowflake utilisée dans les tâches AWS Glue ETL. Lors de l'indexation de Snowflake, utilisez une connexion JDBC.

URL de Snowflake

L'URL de votre point de terminaison Snowflake. Pour plus d'informations sur le point de terminaison Snowflake URLs, consultez la section [Connexion à vos comptes](#) dans la documentation Snowflake.

AWS Secret

Le nom secret d'un secret dans AWS Secrets Manager. AWS Glue se connectera à Snowflake en utilisant les `sfPassword` clés `sfUser` et de votre secret.

Rôle Snowflake (facultatif)

Un rôle de sécurité Snowflake AWS Glue sera utilisé lors de la connexion.

Utilisez les propriétés suivantes lors de la configuration d'une connexion à un point de terminaison Snowflake hébergé dans Amazon VPC en utilisant AWS PrivateLink.

VPC

Choisissez le nom du cloud privé virtuel (VPC) qui contient votre magasin de données. La AWS Glue console répertorie tout VPCs pour la région actuelle.

Sous-réseau

Choisissez le sous-réseau du VPC qui contient votre magasin de données. La console AWS Glue répertorie tous les sous-réseaux pour le magasin de données de votre VPC.

Groupes de sécurité

Choisissez les groupes de sécurité associés à votre banque de données. AWS Glue nécessite un ou plusieurs groupes de sécurité dotés d'une règle de source entrante qui permet de se AWS Glue connecter. La AWS Glue console répertorie tous les groupes de sécurité auxquels un accès entrant est accordé à votre VPC. AWS Glue associe ces groupes de sécurité à l'interface elastic network attachée à votre sous-réseau VPC.

Connexion Vertica

Utilisez les propriétés suivantes pour configurer une connexion Vertica pour les tâches AWS Glue ETL.

Hôte Vertica

Le nom d'hôte de votre installation Vertica.

Port Vertica

Le port via lequel est disponible votre installation Vertica.

AWS Secret

Le nom secret d'un secret dans AWS Secrets Manager. AWS Glue se connectera à Vertica en utilisant les clés de votre secret.

Utilisez les propriétés suivantes lors de la configuration d'une connexion à un point de terminaison Vertica hébergé dans Amazon VPC.

VPC

Choisissez le nom du cloud privé virtuel (VPC) qui contient votre magasin de données. La AWS Glue console répertorie tout VPCs pour la région actuelle.

Sous-réseau

Choisissez le sous-réseau du VPC qui contient votre magasin de données. La console AWS Glue répertorie tous les sous-réseaux pour le magasin de données de votre VPC.

Groupes de sécurité

Choisissez les groupes de sécurité associés à votre banque de données. AWS Glue nécessite un ou plusieurs groupes de sécurité dotés d'une règle de source entrante qui permet de se AWS Glue connecter. La AWS Glue console répertorie tous les groupes de sécurité auxquels un accès entrant est accordé à votre VPC. AWS Glue associe ces groupes de sécurité à l'interface elastic network attachée à votre sous-réseau VPC.

Connexion SAP HANA

Utilisez les propriétés suivantes pour configurer une connexion SAP HANA pour les tâches AWS Glue ETL.

URL SAP HANA

UNE URL SAP JDBC.

SAP HANA JDBC se présente sous la URL suivante :

`jdbc:sap://saphanaHostname:saphanaPort?databaseName=saphanaDBname,ParameterName`

AWS Glue nécessite les paramètres d'URL JDBC suivants :

- `databaseName` – une base de données par défaut dans SAP HANA à laquelle se connecter.

AWS Secret

Le nom secret d'un secret dans AWS Secrets Manager. AWS Glue se connectera à SAP HANA à l'aide des clés de votre secret.

Utilisez les propriétés suivantes lors de la configuration d'une connexion à un point de terminaison SAP HANA hébergé dans Amazon VPC :

VPC

Choisissez le nom du cloud privé virtuel (VPC) qui contient votre magasin de données. La AWS Glue console répertorie tous les VPCs pour la région actuelle.

Sous-réseau

Choisissez le sous-réseau du VPC qui contient votre magasin de données. La console AWS Glue répertorie tous les sous-réseaux pour le magasin de données de votre VPC.

Groupes de sécurité

Choisissez les groupes de sécurité associés à votre banque de données. AWS Glue nécessite un ou plusieurs groupes de sécurité dotés d'une règle de source entrante qui permet de se connecter. La AWS Glue console répertorie tous les groupes de sécurité auxquels un accès entrant est accordé à votre VPC. AWS Glue associe ces groupes de sécurité à l'interface elastic network attachée à votre sous-réseau VPC.

Connexion Azure SQL

Utilisez les propriétés suivantes pour configurer une connexion Azure SQL pour les tâches AWS Glue ETL.

URL Azure SQL

URL JDBC d'un endpoint Azure SQL.

La URL doit avoir le format suivant :

```
jdbc:sqlserver://databaseServerName:databasePort;databaseName=azuresqlDBName;
```

AWS Glue nécessite les propriétés d'URL suivantes :

- `databaseName` – une base de données par défaut dans Azure SQL à laquelle se connecter.

Pour plus d'informations sur JDBC URLs pour Azure SQL Managed Instances, consultez la documentation [Microsoft](#).

AWS Secret

Le nom secret d'un secret dans AWS Secrets Manager. AWS Glue se connectera à Azure SQL à l'aide des clés de votre secret.

Connexion Teradata Vantage

Utilisez les propriétés suivantes pour configurer une connexion Teradata Vantage pour les tâches AWS Glue ETL.

URL de Teradata

Pour vous connecter à une instance Teradata, spécifiez le nom d'hôte de l'instance de base de données et les paramètres Teradata pertinents :

```
jdbc:teradata://teradataHostname/ParameterName=ParameterValue,ParameterName=Pa
```

AWS Glue prend en charge les paramètres d'URL JDBC suivants :

- `DATABASE_NAME` – une base de données par défaut dans Teradata à laquelle se connecter.
- `DBS_PORT` – spécifie le port Teradata, s'il n'est pas standard.

AWS Secret

Le nom secret d'un secret dans AWS Secrets Manager. AWS Glue se connectera à Teradata Vantage à l'aide des clés de votre secret.

Utilisez les propriétés suivantes lors de la configuration d'une connexion à un point de terminaison Teradata Vantage hébergé dans Amazon VPC :

VPC

Choisissez le nom du cloud privé virtuel (VPC) qui contient votre magasin de données. La AWS Glue console répertorie tout VPCs pour la région actuelle.

Sous-réseau

Choisissez le sous-réseau du VPC qui contient votre magasin de données. La console AWS Glue répertorie tous les sous-réseaux pour le magasin de données de votre VPC.

Groupes de sécurité

Choisissez les groupes de sécurité associés à votre banque de données. AWS Glue nécessite un ou plusieurs groupes de sécurité dotés d'une règle de source entrante qui permet de se AWS Glue connecter. La AWS Glue console répertorie tous les groupes de sécurité auxquels un accès entrant est accordé à votre VPC. AWS Glue associe ces groupes de sécurité à l'interface elastic network attachée à votre sous-réseau VPC.

OpenSearch Connexion au service

Utilisez les propriétés suivantes pour configurer une connexion de OpenSearch service pour les tâches AWS Glue ETL.

Point de terminaison de domaine

Un point de terminaison de domaine Amazon OpenSearch Service aura le formulaire par défaut suivant, `https://search - domainName -unstructuredIdContent. region.es.amazonaws.com`. Pour plus d'informations sur l'identification du point de terminaison de votre domaine, consultez la section [Création et gestion des domaines Amazon OpenSearch Service](#) dans la documentation Amazon OpenSearch Service.

Port

Le port ouvert sur le point de terminaison.

AWS Secret

Le nom secret d'un secret dans AWS Secrets Manager. AWS Glue se connectera au OpenSearch Service en utilisant les clés de votre secret.

Utilisez les propriétés suivantes lors de la configuration d'une connexion à un point de terminaison de OpenSearch service hébergé dans Amazon VPC :

VPC

Choisissez le nom du cloud privé virtuel (VPC) qui contient votre magasin de données. La AWS Glue console répertorie tout VPCs pour la région actuelle.

Sous-réseau

Choisissez le sous-réseau du VPC qui contient votre magasin de données. La console AWS Glue répertorie tous les sous-réseaux pour le magasin de données de votre VPC.

Groupes de sécurité

Choisissez les groupes de sécurité associés à votre banque de données. AWS Glue nécessite un ou plusieurs groupes de sécurité dotés d'une règle de source entrante qui permet de se AWS Glue connecter. La AWS Glue console répertorie tous les groupes de sécurité auxquels un accès entrant est accordé à votre VPC. AWS Glue associe ces groupes de sécurité à l'interface elastic network attachée à votre sous-réseau VPC.

Connexion Azure Cosmos

Utilisez les propriétés suivantes pour configurer une connexion Azure Cosmos pour les tâches AWS Glue ETL.

URI du point de terminaison du compte Azure Cosmos DB

Point de terminaison utilisé pour vous connecter à Azure Cosmos. Pour en savoir plus, consultez la [documentation Azure](#).

AWS Secret

Le nom secret d'un secret dans AWS Secrets Manager. AWS Glue se connectera à Azure Cosmos à l'aide des clés de votre secret.

AWS Glue Propriétés de connexion SSL

Vous trouverez ci-dessous des détails sur la propriété Require SSL connection (Connexion SSL obligatoire).

Si vous n'avez pas besoin d'une connexion SSL, AWS Glue ignore les échecs lorsqu'il utilise le protocole SSL pour chiffrer une connexion au magasin de données. Consultez la documentation de

vosre magasin de données pour obtenir les instructions de configuration. Lorsque vous sélectionnez cette option, l'exécution de la tâche, le crawler ou les déclarations ETL dans un point de terminaison de développement échouent lorsque AWS Glue ne parvient pas à se connecter.

 Note

Snowflake prend en charge une connexion SSL par défaut. Cette propriété n'est donc pas applicable à Snowflake.

Cette option est validée côté AWS Glue client. Pour les connexions JDBC, se connecte AWS Glue uniquement via SSL avec validation du certificat et du nom d'hôte. La prise en charge de la connexion SSL est disponible pour :

- Oracle Database
- Microsoft SQL Server
- PostgreSQL
- Amazon Redshift
- MySQL (instances Amazon RDS uniquement)
- Amazon Aurora (instances Amazon RDS uniquement)
- Amazon Aurora PostgreSQL (Instances Amazon RDS uniquement)
- Kafka, qui inclut Amazon Managed Streaming for Apache Kafka
- MongoDB

 Note

Pour permettre à un magasin de données Amazon RDS Oracle d'utiliser Require SSL connection (Connexion SSL obligatoire), vous devez créer et attacher un groupe d'options à l'instance Oracle.

1. Connectez-vous à la console Amazon RDS AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/rds/> l'adresse.
2. Ajoutez un groupe d'options à l'instance Amazon RDS Oracle. Pour plus d'informations sur la façon d'ajouter un groupe d'options à la console Amazon RDS, veuillez consulter [Création d'un groupe d'options](#)

3. Ajoutez une Option au groupe d'options pour SSL. Le port que vous spécifiez pour SSL est ensuite utilisé lorsque vous créez une URL de connexion AWS Glue JDBC pour l'instance Oracle Amazon RDS. Pour plus d'informations sur la façon d'ajouter une option à la console Amazon RDS, veuillez consulter [Ajout d'une option à un groupe d'options](#) dans le Guide de l'utilisateur Amazon RDS. Pour de plus amples informations sur l'option Oracle SSL, veuillez consulter [Oracle SSL](#) dans le Guide de l'utilisateur Amazon RDS.
4. Sur la AWS Glue console, créez une connexion à l'instance Oracle Amazon RDS. Dans la définition de connexion, sélectionnez Require SSL connection (Connexion SSL obligatoire). Lorsque vous y êtes invité, saisissez le port que vous avez utilisé dans l'option Oracle SSL d'Amazon RDS.

Les propriétés facultatives supplémentaires suivantes sont disponibles lorsque l'option Require SSL connection (Connexion SSL obligatoire) est sélectionnée pour une connexion :

Certificat JDBC personnalisé dans S3

Si vous utilisez actuellement un certificat pour les communications SSL avec vos bases de données sur site ou dans le cloud, vous pouvez utiliser ce certificat pour les connexions SSL aux sources de AWS Glue données ou aux cibles. Entrez un emplacement Amazon Simple Storage Service (Amazon S3) contenant un certificat racine personnalisé. AWS Glue utilise ce certificat pour établir une connexion SSL avec la base de données. AWS Glue gère uniquement les certificats X.509. Le certificat doit être codé DER et fourni au format PEM d'encodage Base64.

Si ce champ est laissé vide, le certificat par défaut est utilisé.

Chaîne de certificat JDBC personnalisé

Saisissez les informations de certificat spécifiques à votre base de données JDBC. Il s'agit d'une chaîne utilisée pour la mise en correspondance des domaines ou des noms uniques (DN). Pour Oracle Database, cette chaîne est mappée sur le paramètre SSL_SERVER_CERT_DN dans la section de sécurité du fichier `tnsnames.ora`. Pour Microsoft SQL Server, elle est utilisée comme `hostNameInCertificate`.

Voici un exemple de paramètre SSL_SERVER_CERT_DN pour Oracle Database.

```
cn=sales,cn=OracleContext,dc=us,dc=example,dc=com
```

Emplacement du certificat d'autorité de certification privé Kafka

Si vous avez un certificat que vous utilisez actuellement pour les communications SSL avec votre banque de données Kafka, vous pouvez utiliser ce certificat avec votre AWS Glue connexion. Cette option est obligatoire pour les magasins de données Kafka et facultative pour les magasins de Amazon Managed Streaming for Apache Kafka données. Entrez un emplacement Amazon Simple Storage Service (Amazon S3) contenant un certificat racine personnalisé. AWS Glue utilise ce certificat pour établir une connexion SSL avec le magasin de données Kafka. AWS Glue gère uniquement les certificats X.509. Le certificat doit être codé DER et fourni au format PEM d'encodage Base64.

Ignorer la validation des certificats

Cochez la case Ignorer la validation du certificat pour ignorer la validation du certificat personnalisé par AWS Glue. Si vous choisissez de valider, AWS Glue valide l'algorithme de signature et l'algorithme de clé publique du sujet du certificat. Si la validation du certificat échoue, toute tâche ETL ou crawler qui utilise la connexion échoue.

Les seuls algorithmes de signature autorisés sont SHA256with RSA, SHA384with RSA ou SHA512with RSA. Pour l'algorithme de clé publique d'objet, la longueur de clé doit être d'au moins 2048.

Emplacement du magasin de clés client Kafka

Emplacement Amazon S3 du fichier de magasin de clés client pour l'authentification côté client Kafka. Le chemin doit être au format s3 ://bucket/prefix/filename.jks. Il doit se terminer par le nom du fichier et l'extension .jks.

Mot de passe du magasin de clés client Kafka (facultatif)

Le mot de passe pour accéder au magasin de clés fourni.

Mot de passe de la clé client Kafka (facultatif)

Un magasin de clés peut être composé de plusieurs clés, il s'agit donc du mot de passe pour accéder à la clé client à utiliser avec la clé côté serveur Kafka.

Propriétés de connexion Apache Kafka pour l'authentification du client

AWS Glue prend en charge le framework SASL (Simple Authentication and Security Layer) pour l'authentification lorsque vous créez une connexion Apache Kafka. Le framework SASL prend en

charge divers mécanismes d'authentification et AWS Glue propose les protocoles SCRAM (nom d'utilisateur et mot de passe), GSSAPI (protocole Kerberos) et PLAIN.

AWS Glue Studio À utiliser pour configurer l'une des méthodes d'authentification client suivantes. Pour plus d'informations, consultez la section [Création de connexions pour les connecteurs](#) dans le guide de AWS Glue Studio l'utilisateur.

- Aucune - Aucune authentification. Cette option est utile si vous créez une connexion pour des raisons de tests.
- SASL/SCRAM-SHA-512 - Le choix de cette méthode d'authentification vous permettra de spécifier les informations d'identification d'authentification. Deux options s'offrent à vous :
 - Utiliser AWS Secrets Manager (recommandé) : si vous sélectionnez cette option, vous pouvez enregistrer votre nom d'utilisateur et votre mot de passe dans AWS Secrets Manager et y AWS Glue accéder en cas de besoin. Spécifiez le secret qui stocke les informations d'identification d'authentification SSL ou SASL. Pour plus d'informations, consultez [Stockage des informations de connexion dans AWS Secrets Manager](#).
 - Fournissez directement un nom d'utilisateur et un mot de passe.
- SASL/GSSAPI (Kerberos) - if you select this option, you can select the location of the keytab file, krb5.conf file and enter the Kerberos principal name and Kerberos service name. The locations for the keytab file and krb5.conf file must be in an Amazon S3 location. Since MSK does not yet support SASL/GSSAPI, cette option n'est disponible que pour les clusters Apache Kafka gérés par le client. Pour en savoir plus, consultez [MIT Kerberos Documentation: Keytab](#) (Documentation du MIT Kerberos : Keytab).
- SASL/PLAIN : choisissez cette méthode d'authentification pour spécifier les informations d'authentification. Deux options s'offrent à vous :
 - Utiliser AWS Secrets Manager (recommandé) : si vous sélectionnez cette option, vous pouvez enregistrer vos informations d'identification dans AWS Secrets Manager et autoriser l' AWS Glue accès aux informations en cas de besoin. Spécifiez le secret qui stocke les informations d'identification d'authentification SSL ou SASL.
 - Entrez directement le nom d'utilisateur et le mot de passe.
- Authentification client SSL : si vous sélectionnez cette option, vous pouvez sélectionner l'emplacement du centre de stockage des clés client Kafka en naviguant sur Amazon S3. Vous pouvez également entrer le mot de passe du centre de stockage des clés client Kafka et le mot de passe de la clé client Kafka.

BigQuery Connexion à Google

Les propriétés suivantes sont utilisées pour configurer une BigQuery connexion Google utilisée dans les tâches AWS Glue ETL. Pour de plus amples informations, veuillez consulter [the section called “BigQuery connexions”](#).

AWS Secret

Le nom secret d'un secret dans AWS Secrets Manager. AWS Glue Les tâches ETL se connecteront à Google à l' BigQuery aide de la `credentials` clé de votre secret.

Connexion Vertica

Les propriétés suivantes sont utilisées pour configurer une connexion Vertica utilisée dans les tâches AWS Glue ETL. Pour de plus amples informations, veuillez consulter [the section called “Connexions Vertica”](#).

Stockage des informations de connexion dans AWS Secrets Manager

Nous vous recommandons de l'utiliser AWS Secrets Manager pour fournir des informations d'identification de connexion pour votre banque de données. L'utilisation de Secrets Manager permet d' AWS Glue accéder à votre secret au moment de l'exécution pour les tâches ETL et les exécutions de robots d'exploration, et contribue à la sécurité de vos informations d'identification.

Prérequis

Pour utiliser Secrets Manager avec AWS Glue, vous devez accorder à votre [rôle IAM AWS Glue l'autorisation](#) de récupérer des valeurs secrètes. La politique AWS gérée `AWSGlueServiceRole` n'inclut pas AWS Secrets Manager les autorisations. Pour obtenir des exemples de politiques IAM, consultez la rubrique [Exemple : Autorisation pour récupérer des valeurs de secrets](#) dans le Guide de l'utilisateur AWS Secrets Manager.

En fonction de votre configuration réseau, vous devrez peut-être également créer un point de terminaison d'un VPC pour établir une connexion privée entre votre VPC et gestionnaire de secrets. Pour plus d'informations, consultez la rubrique [Utilisation d'un point de terminaison d'un VPC AWS Secrets Manager](#).

Pour créer un secret pour AWS Glue

1. Suivez les instructions de la rubrique [Création et gestion des secrets](#) dans le AWS Secrets Manager Guide de l'utilisateur . L'exemple JSON suivant montre comment spécifier vos informations d'identification dans l'onglet Texte brut lorsque vous créez un secret pour AWS Glue.

```
{
  "username": "EXAMPLE-USERNAME",
  "password": "EXAMPLE-PASSWORD"
}
```

2. Associez votre secret à une connexion via l' AWS Glue Studio interface. Pour plus d'informations, consultez [Creating connections for connectors](#) dans le Guide de l'utilisateur AWS Glue Studio .

Ajouter une AWS Glue connexion

Vous pouvez vous connecter aux sources de données AWS Glue de Spark par programmation. Pour de plus amples informations, consultez [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#).

Vous pouvez également utiliser la AWS Glue console pour ajouter, modifier, supprimer et tester des connexions. Pour plus d'informations sur AWS Glue les connexions, consultez [Connexion aux données](#).

Rubriques

- [Connexion à Adobe Analytics](#)
- [Connexion à Adobe Marketo Engage](#)
- [Connexion à Amazon Redshift en AWS Glue Studio](#)
- [Connexion à Asana](#)
- [Connexion à Azure Cosmos DB dans AWS Glue Studio](#)
- [Connexion à Azure SQL dans AWS Glue Studio](#)
- [Connexion à Blackbaud Raiser's Edge NXT](#)
- [Connexion à CircleCI](#)
- [Connexion à Datadog](#)

- [Connexion à Docusign Monitor](#)
- [Connexion à Domo](#)
- [Connexion à Dynatrace](#)
- [Connexion aux publicités Facebook](#)
- [Connexion à Facebook Page Insights](#)
- [Connexion à Freshdesk](#)
- [Connexion à Freshsales](#)
- [Connexion à Google Ads](#)
- [Connexion à Google Analytics 4](#)
- [Connexion à Google BigQuery en AWS Glue Studio](#)
- [Connexion à la console de recherche Google](#)
- [Connexion à Google Sheets](#)
- [Connexion à HubSpot](#)
- [Connexion aux publicités Instagram](#)
- [Connexion à Intercom in AWS Glue Studio](#)
- [Connexion à Jira Cloud](#)
- [Connexion à Kustomer](#)
- [Connexion à LinkedIn](#)
- [Connexion à Mailchimp](#)
- [Connexion à Microsoft Teams](#)
- [Connexion à Mixpanel](#)
- [Connexion au lundi](#)
- [Connexion à MongoDB dans AWS Glue Studio](#)
- [Connexion à Oracle NetSuite](#)
- [Connexion au OpenSearch service dans AWS Glue Studio](#)
- [Connexion à Okta](#)
- [Connexion à PayPal](#)
- [Connexion à Pendo](#)
- [Connexion à Pipedrive](#)
- [Connexion à Productboard](#)

- [Connexion à QuickBooks](#)
- [Connexion à Salesforce](#)
- [Connexion à Salesforce Marketing Cloud](#)
- [Connexion à Salesforce Commerce Cloud](#)
- [Connexion à Salesforce Marketing Cloud Account Engagement](#)
- [Connexion à SAP HANA dans AWS Glue Studio](#)
- [Connexion à SAP OData](#)
- [Connexion à SendGrid](#)
- [Connexion à ServiceNow](#)
- [Connexion à Slack en AWS Glue Studio](#)
- [Connexion à Smartsheet](#)
- [Connexion aux publicités Snapchat dans AWS Glue Studio](#)
- [Connexion à Snowflake dans AWS Glue Studio](#)
- [Connexion à Stripe dans AWS Glue Studio](#)
- [Connexion à Teradata Vantage dans AWS Glue Studio](#)
- [Connexion à Twilio](#)
- [Connexion à Vertica dans AWS Glue Studio](#)
- [Connexion à WooCommerce](#)
- [Connexion à Zendesk](#)
- [Connexion à Zoho CRM](#)
- [Connexion à Zoom Meetings](#)
- [Ajout d'une connexion JDBC à l'aide de vos propres pilotes JDBC](#)

Connexion à Adobe Analytics

Adobe Analytics est une plate-forme d'analyse de données robuste qui collecte des données à partir d'expériences numériques multicanales qui soutiennent le parcours client et fournit des outils pour analyser les données. Il s'agit d'une plate-forme couramment utilisée par les spécialistes du marketing et les analystes commerciaux à des fins d'analyse commerciale. Si vous êtes un utilisateur d'Adobe Analytics, vous pouvez vous connecter AWS Glue à votre compte Adobe Analytics. Vous pouvez ensuite utiliser Adobe Analytics comme source de données dans vos tâches ETL. Exécutez

ces tâches pour transférer des données entre Adobe Analytics et les AWS services ou autres applications prises en charge.

Rubriques

- [AWS Glue support pour Adobe Analytics](#)
- [Politiques contenant les opérations d'API pour la création et l'utilisation de connexions](#)
- [Configuration d'Adobe Analytics](#)
- [Configuration des connexions Adobe Analytics](#)
- [Lecture à partir d'entités Adobe Analytics](#)
- [Options de connexion à Adobe Analytics](#)
- [Création d'un compte Adobe Analytics](#)
- [Limites](#)

AWS Glue support pour Adobe Analytics

AWS Glue prend en charge Adobe Analytics comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données d'Adobe Analytics.

Soutenu en tant que cible ?

Non.

Versions d'API Adobe Analytics prises en charge

v2.0

Politiques contenant les opérations d'API pour la création et l'utilisation de connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
```

```
        "Effect": "Allow",
        "Action": [
            "glue:ListConnectionTypes",
            "glue:DescribeConnectionType",
            "glue:RefreshOAuth2Tokens",
            "glue:ListEntities",
            "glue:DescribeEntity"
        ],
        "Resource": "*"
    }
}
```

Si vous ne souhaitez pas utiliser la méthode précédente, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#) — Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#) — Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration d'Adobe Analytics

Avant de pouvoir AWS Glue effectuer un transfert depuis Adobe Analytics, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous disposez d'un compte Adobe Analytics avec adresse e-mail et mot de passe. Pour plus d'informations sur la création d'un compte, voir [Création d'un compte Adobe Analytics](#).
- Votre compte Adobe Analytics est activé pour accéder à l'API. L'accès à l'API est activé par défaut pour les éditions Select, Prime et Ultimate.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Adobe Analytics. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Adobe Analytics.

Configuration des connexions Adobe Analytics

Adobe Analytics prend en charge le type de `AUTHORIZATION_CODE` subvention pour `OAuth2`.

Ce type de subvention est considéré comme « à trois étapes » `OAuth` car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Les utilisateurs peuvent choisir de créer leur propre application connectée dans Adobe Analytics et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Adobe Analytics pour se connecter et autoriser AWS Glue l'accès à leurs ressources.

Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.

[Pour consulter la documentation publique d'Adobe Analytics sur la création d'une application connectée pour le OAuth flux `AUTHORIZATION\_CODE`, consultez Adobe Analytics. APIs](#)

Pour configurer une connexion Adobe Analytics, procédez comme suit :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :

Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.

Note

Il est indispensable de créer un secret par connexion AWS Glue.

2. Dans AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Adobe Analytics.
 - b. Indiquez le `x_api_key`, `instanceUrl` fichier Adobe Analytics auquel vous souhaitez vous connecter.
 - c. Sélectionnez le rôle IAM pour lequel AWS Glue vous pouvez assumer et qui dispose des autorisations nécessaires pour effectuer les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
- e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture à partir d'entités Adobe Analytics

Prérequis

Un objet Adobe Analytics dont vous souhaitez lire un extrait. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Annotation	Oui	Oui	Oui	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Métriques calculées	Oui	Oui	Oui	Oui	Non
Fonction de mesures calculées	Oui	Non	Non	Oui	Non
Partage des métadonnées des composants	Oui	Oui	Non	Oui	Non
Plages de dates	Oui	Oui	Non	Oui	Non
Dimensions	Oui	Non	Non	Oui	Non
Métriques	Oui	Non	Non	Oui	Non
Projets	Oui	Non	Non	Oui	Non
Article le plus important des rapports	Oui	Oui	Non	Oui	Non
Segments	Oui	Oui	Oui	Oui	Non
Journaux d'utilisation	Oui	Oui	Non	Oui	Non

Exemple

```
adobeAnalytics_read = glueContext.create_dynamic_frame.from_options(
    connection_type="adobeanalytics",
    connection_options={
```

```
"connectionName": "connectionName",  
"ENTITY_NAME": "annotation/ex*****",  
"API_VERSION": "v2.0"  
})
```

Informations sur les entités et les champs Adobe Analytics

- [Annotations](#)
- [Métriques calculées](#)
- [Méta-données des composants](#)
- [Plages de dates](#)
- [Dimensions](#)
- [Métriques](#)
- [Projets](#)
- [Rapports](#)
- [Segments](#)
- [Utilisateurs](#)
- [Journaux d'utilisation](#)

Options de connexion à Adobe Analytics

Les options de connexion pour Adobe Analytics sont les suivantes :

- ENTITY_NAME(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Adobe Analytics.
- API_VERSION(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Rest d'Adobe Analytics que vous souhaitez utiliser. Par exemple : v2.0.
- X_API_KEY(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Il est nécessaire d'authentifier le développeur ou l'application qui envoie des demandes à l'API.
- SELECTED_FIELDS(Liste<String>) — Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- FILTER_PREDICATE(String) — Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- QUERY(String) — Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

Création d'un compte Adobe Analytics

1. Inscrivez-vous au programme d'échange de partenaires en accédant au [programme Adobe Partner](#).
2. Choisissez Rejoindre le programme d'échange.
3. Inscrivez-vous ou créez un compte en utilisant votre adresse e-mail professionnelle.
4. Dans la boîte à suggestions, sélectionnez l'entreprise appropriée qui possède un abonnement à un produit Adobe Analytics.
5. Assurez-vous que le compte est enregistré auprès d'une organisation valide (dans la liste disponible) disposant d'un abonnement Adobe Analytics actif.
6. Après l'approbation de l'administration de l'entreprise, activez votre compte en cliquant sur le lien contenu dans l'e-mail d'approbation.

Vérifier si le compte que vous avez créé a accès au service Adobe Analytics

1. Connectez-vous à [Adobe Admin Console](#).
2. Vérifiez le nom de l'organisation dans le coin supérieur droit de la page pour vous assurer que vous vous êtes connecté à la bonne entreprise.
3. Sélectionnez Produits et vérifiez si Adobe Analytics est disponible.

Note

Si aucune organisation n'est disponible, ou si le produit Adobe Analytics est grisé ou n'est pas disponible, il est probable que votre compte ne soit pas associé à une organisation et/ou qu'il n'y ait aucun abonnement Adobe Analytics actif. Contactez votre administrateur système pour demander l'accès à ce service pour votre compte.

Création d'un projet et d'**OAuth2.0** informations d'identification

1. Connectez-vous au compte Adobe Analytics sur lequel vous souhaitez créer [l'application OAuth 2.0](#).
2. Sélectionnez Projet, puis Créez un nouveau projet.
3. Pour ajouter un projet, sélectionnez Ajouter au projet, puis sélectionnez API.
4. Sélectionnez l'API Adobe Analytics.

5. Sélectionnez OAUTH comme authentification utilisateur.
6. Sélectionnez Web as OAUTH et indiquez l'URI de redirection.

Pour l'URI de redirection et son modèle, consultez ce qui suit :

- OAuth 2.0 URI de redirection par défaut : l'URI de redirection par défaut est l'URL de la page à laquelle Adobe accèdera pendant le processus d'authentification. Par exemple, `https://ap-southeast-2.console.aws.amazon.com/appflow/oauth`
 - OAuth Modèle d'URI de redirection 2.0 — Un modèle d'URI de redirection est un chemin d'URI (ou une liste de chemins séparés par des virgules) vers lequel Adobe peut être redirigé (si demandé) une fois le flux de connexion terminé. Par exemple, `https://ap-southeast-2\\.console\\.aws\\.amazon\\.com`
7. Ajoutez les étendues suivantes :
 - `openid`
 - `read_organizations`
 - `additional_info.projectedProductContext`
 - `additional_info.job_function`
 8. Choisissez Enregistrer les informations d'identification.
 9. Une fois l'application créée, copiez les Client Secret valeurs Client ID et dans un fichier texte.

Limites

Les limites du connecteur Adobe Analytics sont les suivantes :

- Adobe Analytics ne prend pas en charge le partitionnement basé sur les champs et basé sur les enregistrements. Le partitionnement basé sur les champs n'est pas pris en charge car vous ne pouvez pas interroger les champs que vous partitionnez. Le partitionnement basé sur les enregistrements ne peut pas être pris en charge car il n'existe aucune disposition permettant d'obtenir un « décalage » pour la pagination.
- Dans l'Report Top Itementité, les paramètres de endDate requête startDate et ne fonctionnent pas comme prévu. La réponse n'est pas filtrée en fonction de ces paramètres, ce qui entraîne des problèmes avec le filtre et le flux incrémentiel pour cette entité.
- Pour les Segment entitésAnnotation,Calculated Metrics,Calculated Metrics Function,Date Ranges,Dimension,Metric,Project, etReport Top Items,,,, et, le

paramètre de `locale` requête indique la langue à utiliser pour les sections localisées des réponses et ne filtre pas les enregistrements. Par exemple, `locale="ja_JP"` affichera les données en japonais.

- **Report Top Itementité** : le filtre est activé `dateRange` et `lookupNoneValues` les champs ne fonctionnent pas actuellement.
- **Segmententité** : avec une valeur de `filterincludeType="templates"`, les filtres sur les autres champs ne fonctionnent pas.
- **Date Rangeentité** : le filtre sur `curatedRsid` le champ ne fonctionne pas.
- **Metric entityentité** — le filtre sur un champ segmentable avec une valeur « fausse » donne un résultat à la fois pour une valeur vraie et une fausse valeur.

Connexion à Adobe Marketo Engage

Adobe Marketo Engage est une plateforme d'automatisation du marketing qui permet aux spécialistes du marketing de gérer des programmes et des campagnes multicanaux personnalisés destinés aux prospects et aux clients.

Rubriques

- [AWS Glue support pour Adobe Marketo Engage](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration d'Adobe Marketo Engage](#)
- [Configuration des connexions Adobe Marketo Engage](#)
- [Lecture à partir d'entités Adobe Marketo Engage](#)
- [Options de connexion d'Adobe Marketo Engage](#)
- [Limitations et remarques relatives au connecteur Adobe Marketo Engage](#)

AWS Glue support pour Adobe Marketo Engage

AWS Glue prend en charge Adobe Marketo Engage comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données d'Adobe Marketo Engage.

Soutenu en tant que cible ?

Non.

Versions de l'API Adobe Marketo Engage prises en charge

Les versions suivantes de l'API Adobe Marketo Engage sont prises en charge :

- v1

Pour la prise en charge des entités par version spécifique, voir Entités prises en charge pour la source.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette

politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration d'Adobe Marketo Engage

Avant de pouvoir AWS Glue transférer des données d'Adobe Marketo Engage, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous possédez un compte Adobe Marketo Engage avec des informations d'identification client.
- Votre compte Adobe Marketo Engage dispose d'un accès à l'API avec une licence valide.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Adobe Marketo Engage. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Adobe Marketo Engage.

Obtenir des informations d'identification OAuth 2.0

Pour obtenir des informations d'identification d'API afin de pouvoir effectuer des appels authentifiés vers votre instance, consultez la section [API REST](#) dans le guide du développeur d'Adobe Marketo Engage.

Configuration des connexions Adobe Marketo Engage

Adobe Marketo Engage prend en charge le type de subvention CLIENT CREDENTIALS pour OAuth2.

- Ce type de subvention est considéré comme une OAuth version 2.0 bidimensionnelle car il est utilisé par les clients pour obtenir un jeton d'accès en dehors du contexte d'un utilisateur. AWS Glue est capable d'utiliser l'ID client et le secret du client pour authentifier l'Adobe Marketo Engage APIs fournis par les services personnalisés que vous définissez.

- Chaque service personnalisé appartient à un utilisateur utilisant uniquement l'API, qui dispose d'un ensemble de rôles et d'autorisations autorisant le service à effectuer des actions spécifiques. Un jeton d'accès est associé à un seul service personnalisé.
- Ce type d'autorisation donne lieu à un jeton d'accès de courte durée qui peut être renouvelé en appelant un point de terminaison d'identité.
- Pour consulter la documentation publique d'Adobe Marketo Engage OAuth 2.0 avec les informations d'identification du client, voir [Authentification](#) dans le guide du développeur d'Adobe Marketo Engage.

Pour configurer une connexion Adobe Marketo Engage :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir le secret du consommateur de l'application connectée avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
 - b. Remarque : Vous devez créer un secret par connexion dans AWS Glue.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Adobe Marketo Engage.
 - b. Indiquez `INSTANCE_URL` l'instance Adobe Marketo Engage à laquelle vous souhaitez vous connecter.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
    }
  ],
}
```



```

        "Resource": "*"
    }
]
}

```

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture à partir d'entités Adobe Marketo Engage

Prérequis

Un objet Adobe Marketo Engage dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet, tel que les prospects, les activités ou les objets personnalisés. Les tableaux suivants indiquent les entités prises en charge.

Entités prises en charge pour la source (synchrone) :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
pistes	Oui	Oui	Non	Oui	Non
activités	Oui	Oui	Non	Oui	Non
objets personnalisés	Oui	Oui	Non	Oui	Non

Entités prises en charge pour la source (asynchrone) :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
pistes	Oui	Non	Non	Oui	Oui

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
activités	Oui	Non	Non	Oui	Non
objets personnalisés	Oui	Non	Non	Oui	Oui

Exemple :

```
adobe-marketo-engage_read = glueContext.create_dynamic_frame.from_options(
    connection_type="adobe-marketo-engage",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "leads",
        "API_VERSION": "v2",
        "INSTANCE_URL": "https://539-t**-6**.mktoest.com"
    }
)
```

Informations sur l'entité et le champ Adobe Marketo Engage :

Entités avec métadonnées statiques :

Entité	Champ	Type de données	Opérateurs pris en charge
activités	SinceDateTime (uniquement pris en charge en mode synchrone)	DateTime	>= (uniquement pour le mode synchrone)
	CreatedAt (uniquement pris en charge en mode asynchrone)	DateTime	entre (uniquement pour le mode asynchrone)
	activitiesTypeld	Entier	=

Entité	Champ	Type de données	Opérateurs pris en charge
	adobe-marketo-engagementGUID	Long	= (uniquement pour le mode synchrone)
	ID de plomb	Long	N/A
	Date de l'activité	DateTime	N/A
	campaignId	Long	N/A
	primaryAttributeValueId	Entier	N/A
	primaryAttributeValue	Chaîne	N/A
	attributs	Chaîne	N/A

Entités dotées de métadonnées dynamiques :

Pour les entités suivantes, Adobe Marketo Engage fournit des points de terminaison permettant de récupérer les métadonnées de manière dynamique, afin que le support des opérateurs soit pris en compte au niveau du type de données pour chaque entité.

Entité	Type de données	Opérateurs pris en charge
pistes	Entier	= (uniquement pour le mode synchrone)
	DateTime	entre (uniquement pour le mode asynchrone)
	Chaîne	= (uniquement pour le mode synchrone)
	Long	N/A
	Booléen	N/A

Entité	Type de données	Opérateurs pris en charge
	Date	N/A
	Float	N/A
objets personnalisés	Entier	N/A
	DateTime	entre (uniquement pour le mode asynchrone)
	Chaîne	= (uniquement pour le mode synchrone)
	Date	N/A
	Long	N/A
	Booléen	N/A
	Float	N/A

Requêtes de partitionnement

Vous pouvez fournir les options supplémentaires de Spark

`PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, et `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur inférieure inclusive du champ de partition choisi.

Pour le `DateTime` champ, nous acceptons la valeur au format ISO.

Exemple de valeur valide :

```
"2024-07-01T00:00:00.000Z"
```

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.

- **NUM_PARTITIONS**: le nombre de partitions.

Le tableau suivant décrit les détails relatifs à la prise en charge des champs de partitionnement des entités :

Nom de l'entité	Champs de partitionnement	Type de données
pistes	createdAt	DateTime
	Mettre à jour à	DateTime
objets personnalisés	updatedAt	DateTime

Exemple :

```
adobe-marketo-engage_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="adobe-marketo-engage",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "leads",  
        "API_VERSION": "v1",  
        "PARTITION_FIELD": "createdAt"  
        "LOWER_BOUND": "2024-07-01T00:00:00.000Z"  
        "UPPER_BOUND": "2024-07-02T00:00:00.000Z"  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Options de connexion d'Adobe Marketo Engage

Les options de connexion pour Adobe Marketo Engage sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Adobe Marketo Engage.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Rest d'Adobe Marketo Engage que vous souhaitez utiliser. Par exemple : v1.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.

- `FILTER_PREDICATE(String)` - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- `QUERY(String)` - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- `PARTITION_FIELD(String)` - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- `LOWER_BOUND(String)` - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- `UPPER_BOUND(String)` - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS(Entier)` - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.
- `TRANSFER_MODE(String)` - Par défaut : SYNC. Utilisé pour la lecture asynchrone.

Limitations et remarques relatives au connecteur Adobe Marketo Engage

Les limitations ou remarques suivantes concernent le connecteur Adobe Marketo Engage :

- « `SinceDateTime` » et « `activityTypeId` » sont des paramètres de filtre obligatoires pour l'entité Sync Activities.
- Les abonnements reçoivent 50 000 appels d'API par jour (réinitialisés tous les jours à minuit CST). Une capacité quotidienne supplémentaire peut être achetée dans le cadre d'un abonnement Adobe Marketo Engage.
- La durée maximale pour le filtre de plage de dates (`createdAtouupdatedAt`) est de 31 jours.
- Les abonnements se voient attribuer un maximum de 10 tâches d'extraction en bloc dans la file d'attente à un moment donné.
- Par défaut, les tâches d'extraction sont limitées à 500 Mo par jour (réinitialisation quotidienne à minuit CST). Une capacité quotidienne supplémentaire peut être achetée dans le cadre d'un abonnement Adobe Marketo Engage.
- Le nombre maximum de tâches d'exportation simultanées est de 2.
- Le nombre maximum d'emplois d'exportation en attente (y compris les emplois actuellement en cours d'exportation) est de 10.
- La taille de fichier maximale autorisée est de 1 Go pour l'extraction à partir d'une tâche groupée.
- Une fois qu'une tâche asynchrone est créée, la période de conservation des fichiers sera de 7 jours avant l'expiration.
- `createdAtouupdatedAt` sont des paramètres de filtre obligatoires pour l'entité Async Leads.

- `createdAt` est un paramètre de filtre obligatoire pour l'entité Async Activities.
- `updatedAt` est un paramètre de filtre obligatoire pour l'entité Async Custom Object.

Pour plus d'informations, consultez les [meilleures pratiques d'intégration d'Adobe Marketo Engage](#) et [l'extraction en bloc](#).

Connexion à Amazon Redshift en AWS Glue Studio

Note

Vous pouvez utiliser ... AWS Glue pour que Spark puisse lire et écrire dans des tables de Amazon Redshift bases de données situées en dehors de AWS Glue Studio. Pour configurer Amazon Redshift avec AWS Glue emplois programmés, voir [Connexions Redshift](#).

AWS Glue fournit un support intégré pour Amazon Redshift. AWS Glue Studio fournit une interface visuelle pour se connecter Amazon Redshift, créer des tâches d'intégration de données et les exécuter sur AWS Glue Studio environnement d'exécution Spark sans serveur.

Rubriques

- [Création d'une Amazon Redshift connexion](#)
- [Création d'un nœud Amazon Redshift source](#)
- [Création d'un nœud Amazon Redshift cible](#)
- [Options avancées](#)

Création d'une Amazon Redshift connexion

Autorisations nécessaires

Des autorisations supplémentaires sont nécessaires pour utiliser les Amazon Redshift clusters et les environnements Amazon Redshift sans serveur. Pour plus d'informations sur la façon d'ajouter des autorisations aux tâches ETL, consultez [Review IAM permissions needed for ETL jobs](#).

- décalage vers le rouge : DescribeClusters
- redshift-serverless : ListWorkgroups
- redshift-serverless : ListNamespaces

Présentation

Lorsque vous ajoutez une Amazon Redshift connexion, vous pouvez choisir une Amazon Redshift connexion existante ou créer une nouvelle connexion lors de l'ajout d'une source de données - nœud Redshift dans AWS Glue Studio.

AWS Glue prend en charge à la fois les Amazon Redshift clusters et les environnements Amazon Redshift sans serveur. Lorsque vous créez une connexion, les environnements Amazon Redshift sans serveur affichent l'étiquette sans serveur à côté de l'option de connexion.

Pour plus d'informations sur la création d'une Amazon Redshift connexion, consultez la section [Déplacement de données vers et depuis Amazon Redshift](#).

Création d'un nœud Amazon Redshift source

Autorisations nécessaires

AWS Glue Studio les tâches utilisant Amazon Redshift des sources de données nécessitent des autorisations supplémentaires. Pour plus d'informations sur la façon d'ajouter des autorisations aux tâches ETL, consultez [Review IAM permissions needed for ETL jobs](#).

Les autorisations suivantes sont nécessaires pour utiliser une Amazon Redshift connexion.

- données redshift : ListSchemas
- données redshift : ListTables
- données redshift : DescribeTable
- données redshift : ExecuteStatement
- données redshift : DescribeStatement
- données redshift : GetStatementResult

Ajouter une source Amazon Redshift de données

Pour ajouter un nœud Source de données – Amazon Redshift :

1. Choisissez le type Amazon Redshift d'accès :
 - Connexion directe aux données (recommandée) : choisissez cette option si vous souhaitez accéder directement à vos données Amazon Redshift . Il s'agit de l'option recommandée, mais également de l'option par défaut.

- Data Catalog tables — choisissez cette option si vous souhaitez utiliser des tables du catalogue de données.
2. Si vous choisissez Connexion directe aux données, choisissez la connexion pour votre source de Amazon Redshift données. Cela suppose que la connexion existe déjà et que vous pouvez la sélectionner parmi les connexions existantes. Si vous devez créer une connexion, choisissez Créer une connexion Redshift. Pour en savoir plus, consultez [Overview of using connectors and connections](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés. Les informations relatives à la connexion sont visibles, notamment l'URL, les groupes de sécurité, le sous-réseau, la zone de disponibilité, la description et les horodatages de création (UTC) et de dernière mise à jour (UTC).

3. Choisissez une option Amazon Redshift de source :
 - Choisissez une seule table : il s'agit de la table qui contient les données auxquelles vous souhaitez accéder à partir d'une seule Amazon Redshift table.
 - Saisir une requête personnalisée : vous permet d'accéder à un jeu de données à partir de plusieurs tables Amazon Redshift en fonction de votre requête personnalisée.
4. Si vous avez choisi une seule table, choisissez le Amazon Redshift schéma. La liste des schémas disponibles parmi lesquels choisir est déterminée par la table sélectionnée.

Vous pouvez également choisir Saisir une requête personnalisée. Choisissez cette option pour accéder à un jeu de données personnalisé à partir de plusieurs tables Amazon Redshift. Lorsque vous choisissez cette option, entrez la Amazon Redshift requête.

Lorsque vous vous connectez à un environnement Amazon Redshift sans serveur, ajoutez l'autorisation suivante à la requête personnalisée :

```
GRANT SELECT ON ALL TABLES IN <schema> TO PUBLIC
```

Vous pouvez choisir Dédire un schéma pour lire le schéma en fonction de la requête que vous avez saisie. Vous pouvez également choisir l'éditeur de requêtes Open Redshift pour saisir une Amazon Redshift requête. Pour plus d'informations, consultez [Interrogation d'une base de données à l'aide de l'éditeur de requête](#).

5. Dans Performances et sécurité, choisissez le répertoire intermédiaire Amazon S3 et le rôle IAM.

- Répertoire intermédiaire Amazon S3 : choisissez l'emplacement Amazon S3 pour les données intermédiaires temporaires.
 - Rôle IAM : choisissez le rôle IAM qui peut écrire sur l'emplacement Amazon S3 que vous avez sélectionné.
6. Dans Paramètres Redshift personnalisés – facultatif, saisissez le paramètre et la valeur.

Création d'un nœud Amazon Redshift cible

Autorisations nécessaires

AWS Glue Studio les tâches utilisant une cible de Amazon Redshift données nécessitent des autorisations supplémentaires. Pour plus d'informations sur la façon d'ajouter des autorisations aux tâches ETL, consultez [Review IAM permissions needed for ETL jobs](#).

Les autorisations suivantes sont nécessaires pour utiliser une Amazon Redshift connexion.

- données redshift : ListSchemas
- données redshift : ListTables

Ajouter un nœud Amazon Redshift cible

Pour créer un nœud Amazon Redshift cible :

1. Choisissez une Amazon Redshift table existante comme cible ou entrez un nouveau nom de table.
2. Lorsque vous utilisez le nœud cible Cible de données – Redshift, vous pouvez choisir l'une des options suivantes :
 - APPREND : si une table existe déjà, insérez toutes les nouvelles données dans la table sous forme d'insertion. Si la table n'existe pas, créez-la, puis insérez toutes les nouvelles données.

Cochez également la case si vous souhaitez mettre à jour (UPSERT) les enregistrements existants dans la table cible. La table doit d'abord exister, sinon l'opération échouera.

 - FUSIONNER — AWS Glue mettra à jour ou ajoutera des données à votre table cible en fonction des conditions que vous spécifiez.

 Note

Pour utiliser l'action de fusion dans AWS Glue, vous devez activer la fonctionnalité de Amazon Redshift fusion. Pour savoir comment activer la fusion pour votre Amazon Redshift instance, consultez [MERGE \(aperçu\)](#).

Choisissez parmi les options :

- Choisir des clés et des actions simples : choisissez les colonnes à utiliser comme clés de correspondance entre les données source et votre jeu de données cible.

Spécifiez les options suivantes lorsqu'elles correspondent :

- Mettez à jour l'enregistrement dans votre jeu de données cible avec les données de la source.
- Supprimez l'enregistrement dans votre jeu de données cible.

Spécifiez les options suivantes lorsqu'elles ne correspondent pas :

- Insérez les données source en tant que nouvelle ligne dans votre jeu de données cible.
- Ne rien faire.
- Saisir une instruction MERGE personnalisée : vous pouvez ensuite choisir Valider l'instruction de fusion pour vérifier si l'instruction est valide ou non.
- TRUNCATE : si une table existe déjà, tronquez les données de la table en effaçant d'abord le contenu de la table cible. Si la troncature est réussie, insérez toutes les données. Si la table n'existe pas, créez-la, puis insérez toutes les nouvelles données. Si la troncature échoue, l'opération échouera.
- DROP : si une table existe déjà, supprimez les métadonnées et les données de la table. Si la suppression est réussie, insérez toutes les données. Si la table n'existe pas, créez-la, puis insérez toutes les nouvelles données. Si la suppression échoue, l'opération échouera.
- CREATE : créez une table avec le nom par défaut. Si le nom de la table existe déjà, créez-en une avec le suffixe `_job_datetime` au nom pour garantir son unicité. Toutes les données seront alors insérées dans la nouvelle table. Si la table existe, le suffixe sera ajouté au nom final de la table. Si elle n'existe pas, une table sera créée. Dans les deux cas, une nouvelle table sera créée.

Options avancées

Voir [Utilisation du connecteur Amazon Redshift Spark sur AWS Glue](#).

Connexion à Asana

Asana est une solution de collaboration d'équipe basée sur le cloud qui aide les équipes à organiser, planifier et réaliser des tâches et des projets. Si vous utilisez Asana, votre compte contient des données sur vos espaces de travail, vos projets, vos tâches, vos équipes, etc. Vous pouvez transférer des données d'Asana vers certains AWS services ou d'autres applications compatibles.

Rubriques

- [AWS Glue support pour Asana](#)
- [Politiques contenant les opérations d'API pour la création et l'utilisation de connexions](#)
- [Configuration d'Asana](#)
- [Configuration des connexions Asana](#)
- [Lecture depuis les entités Asana](#)
- [Options de connexion Asana](#)
- [Création d'un compte Asana](#)
- [Limites](#)

AWS Glue support pour Asana

AWS Glue prend en charge Asana comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données d'Asana.

Soutenu en tant que cible ?

Non

Versions d'API Asana prises en charge

1.0

Politiques contenant les opérations d'API pour la création et l'utilisation de connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode précédente, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#) — Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#) — Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration d'Asana

Avant de pouvoir AWS Glue effectuer un transfert depuis Asana, vous devez remplir les conditions suivantes :

Configuration requise

- Vous possédez un compte Asana avec e-mail et mot de passe. Pour plus d'informations sur la création d'un compte, consultez [Création d'un compte Asana](#).
- Vous devez avoir créé AWS un compte avec l'accès au service à AWS Glue.
- Assurez-vous d'avoir créé l'une des ressources suivantes sur votre compte Asana :
 - Une application pour développeurs qui prend en charge OAuth 2.0 l'authentification. Pour plus d'instructions, consultez la documentation destinée [OAuth](#) aux développeurs d'Asana. Sinon, consultez [the section called “Création d'un compte Asana”](#).
 - Un jeton d'accès personnel. Pour plus d'informations, consultez le jeton d'accès personnel <https://developers.asana.com/docs/personal-access-token> dans la documentation destinée aux développeurs d'Asana.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Adobe Analytics. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Adobe Analytics.

Configuration des connexions Asana

Asana prend en charge le type de AUTHORIZATION_CODE subvention pour OAuth2.

Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Les utilisateurs peuvent choisir de créer leur propre application connectée sur Asana et de fournir leur propre identifiant client et leur secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Asana pour se connecter et autoriser l'accès AWS Glue à leurs ressources.

Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.

Pour consulter la documentation publique d'Asana sur la création d'une application connectée pour AUTHORIZATION_CODE OAuth Flow, consultez [Asana APIs](#).

Pour configurer une connexion Asana :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :

- Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET comme clé.

 Note

Vous devez créer un secret pour la connexion dans AWS Glue.

2. Dans AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :

- a. Lorsque vous sélectionnez un type de connexion, sélectionnez Asana.
- b. Fournissez l'environnement Asana.
- c. Sélectionnez le rôle IAM pour lequel AWS Glue vous pouvez assumer et qui dispose des autorisations nécessaires pour effectuer les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture depuis les entités Asana

Prérequis

Un objet Asana dont vous aimeriez lire un extrait. Consultez le tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge pour la source

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Espace de travail	Non	Oui	Non	Oui	Non
Tag	Non	Oui	Non	Oui	Non
Utilisateur	Non	Oui	Non	Oui	Non
Portefeuille	Non	Oui	Non	Oui	Non
Equipe	Non	Oui	Non	Oui	Non
Projet	Oui	Oui	Non	Oui	Non
Section	Non	Oui	Non	Oui	Non
Tâche	Oui	Non	Non	Oui	Oui
Objectif	Oui	Oui	Non	Oui	Non
AuditLogEvent	Oui	Oui	Non	Oui	Non
Mise à jour du statut	Oui	Oui	Non	Oui	Non
Champ personnalisé	Non	Oui	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Résumé du projet	Oui	Non	Non	Oui	Oui

Exemple

```
read_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Asana",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "task/workspace:xxxx",
        "API_VERSION": "1.0",
        "PARTITION_FIELD": "created_at",
        "LOWER_BOUND": "2024-02-05T14:09:30.115Z",
        "UPPER_BOUND": "2024-06-07T13:30:00.134Z",
        "NUM_PARTITIONS": "3"
    }
)
```

Informations sur les entités et les champs Asana

- [Espace de travail](#)
- [Balise](#)
- [Utilisateur](#)
- [Portefeuille](#)
- [L'équipe](#)
- [Projet](#)
- [Rubrique](#)
- [Tâche](#)
- [Objectif](#)
- [AuditLogEvent](#)
- [Mise à jour du statut](#)
- [Champ personnalisé](#)

- [Résumé du projet](#)

Requêtes de partitionnement

Des options Spark supplémentaires `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, `NUM_PARTITIONS` peuvent être fournies si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur inférieure inclusive du champ de partition choisi.

Pour la date, nous acceptons le format de date Spark utilisé dans les requêtes SQL Spark.

Exemple de valeurs valides : `2024-06-07T13:30:00.134Z`.

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`: nombre de partitions.

Les détails relatifs à la prise en charge des champs de partitionnement par entité sont présentés dans le tableau suivant.

Nom de l'entité	Champ de partitionnement	Type de données
Tâche	<code>created_at</code>	DateTime
Tâche	<code>modifié_at</code>	DateTime

Exemple

```
read_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="Asana",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "task/workspace:xxxx",  
        "API_VERSION": "1.0",  
        "PARTITION_FIELD": "created_at",  
        "LOWER_BOUND": "2024-02-05T14:09:30.115Z",  
        "UPPER_BOUND": "2024-06-07T13:30:00.134Z",  
        "NUM_PARTITIONS": "3"  
    }  
)
```

```
}
```

Options de connexion Asana

Les options de connexion pour Asana sont les suivantes :

- **ENTITY_NAME**(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet sur Asana.
- **API_VERSION**(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Asana Rest que vous souhaitez utiliser. Par exemple : 1.0.
- **SELECTED_FIELDS**(Liste<String>) — Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) — Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) — Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Création d'un compte Asana

1. Ouvrez un [compte Asana](#) et choisissez S'inscrire.
2. Une fois connecté, vous serez redirigé vers la page de [configuration du compte](#). Procédez comme suit :
 - Consultez le formulaire de configuration du compte.
 - Renseignez toutes les informations nécessaires pour créer votre compte Asana.
 - Vérifiez l'exactitude des informations.
3. Choisissez Créer un compte ou Soumettre (le texte exact du bouton peut varier) pour finaliser la configuration de votre compte.

Création de l'application sur Asana pour **OAuth2.0**

1. Connectez-vous à votre compte Asana à l'aide de vos informations d'identification [client Asana](#).
2. Choisissez l'icône de votre profil utilisateur dans le coin supérieur droit et sélectionnez Mes paramètres dans le menu déroulant.
3. Sélectionnez l'onglet Applications, puis sélectionnez Gérer les applications pour développeurs.
4. Sélectionnez Créer une nouvelle application et entrez les informations pertinentes.
5. Choisissez Create Apps.
6. Sur la page Mes applications :
 - a. Sélectionnez OAuthet dans la section Informations d'identification de l'application, notez votre identifiant client et votre secret client.
 - b. Dans la URLs section Redirection, ajoutez les URL de redirection nécessaires.

Note

Entrez l'URI de redirection en utilisant ce format :`https://{aws-region-code}.console.aws.amazon.com/gluestudio/oauth`. Exemple :
Pour l'est des États-Unis (Virginie du Nord), utilisez : `https://us-east-1.console.aws.amazon.com/gluestudio/oauth`

Création de l'application sur Asana for Token **PAT**

1. Connectez-vous à votre compte Asana à l'aide de vos informations d'identification [client Asana](#).
2. Choisissez l'icône de votre profil utilisateur dans le coin supérieur droit et sélectionnez Mes paramètres de profil dans le menu déroulant.
3. Sélectionnez l'onglet Applications, puis sélectionnez Comptes de service.
4. Sélectionnez Créer une nouvelle application et entrez les informations pertinentes.
5. Choisissez Ajouter un compte de service.
6. La page suivante affiche votre jeton, copiez-le et stockez-le en toute sécurité.

 Important

Ce jeton ne sera affiché qu'une seule fois. Assurez-vous de le copier et de le stocker en toute sécurité.

Limites

Les limites du connecteur Asana sont les suivantes :

- Les comptes de service dans Enterprise Domains ne peuvent accéder qu'aux points de terminaison de l'API du journal d'audit. L'authentification à l'aide du jeton d'accès personnel d'un compte de service est requise pour accéder à ces points de terminaison.
- L'entité Goal n'est accessible que pour les comptes utilisateurs dotés d'un forfait Premium ou supérieur.
- Audit Log Event Entity— Dans le connecteur, `start_at` et `end_at` champs sont combinés en un seul champ « `start_end_at` » pour prendre en charge le filtrage et le transfert incrémentiel.
- Le partitionnement ne peut pas être pris en charge pour le Date champ, même s'il prend en charge les opérateurs `greater-than-or-equal -to` et `less-than-or-equal -to`. Scénario : création d'une tâche avec `partitionField` as `due_on` (type de données : date), `lowerBound` as `2019-09-14` et `upperBound` as `2019-09-16`, `numPartition` as 2 La partie filtre de l'URL du point de terminaison est créée comme suit :
 - `partition1` : `due_on.before=2019-09-14&due_on.after=2019-09-14`
 - `partition2` : `due_on.before=2019-09-15&due_on.after=2019-09-15` Sortie :
 - Dans la `partition1`, nous obtenons des données dont la date d'échéance est le 14/09/2019 et le 15/09/2019
 - Dans la `partition2`, nous obtenons les mêmes données avec `due_date` que le 2019-09-15 (qui se trouvaient dans la `partition1`) ainsi que d'autres données, ce qui entraîne une duplication des données.
- Le filtrage et le partitionnement ne peuvent pas être pris en charge sur le même champ, car une erreur de demande erronée est renvoyée du côté du SaaS.
- L'entité Task nécessite un minimum d'un champ dans les critères de filtre. Asana présente une limite : la pagination n'est pas identifiée si les enregistrements ne sont pas triés en fonction d'un champ temporel. Par conséquent, le champ `Created_at` est utilisé avec la pagination pour

distinguer le prochain ensemble d'enregistrements. Le champ `Created_at` est marqué comme obligatoire dans le filtre, avec une valeur par défaut de `2000-01-01T 00:00:00 Z` s'il n'est pas fourni. Pour plus d'informations sur la pagination, voir [Tâches dans un espace](#) de travail.

Connexion à Azure Cosmos DB dans AWS Glue Studio

AWS Glue fournit un support intégré pour Azure Cosmos DB. AWS Glue Studio fournit une interface visuelle permettant de se connecter à Azure Cosmos DB pour NoSQL, de créer des tâches d'intégration de données et de les exécuter sur l'environnement d'exécution Spark sans serveur.

Rubriques

- [Création d'une connexion Azure Cosmos DB](#)
- [Création d'un nœud source Azure Cosmos DB](#)
- [Création d'un nœud cible Azure Cosmos DB](#)
- [Options avancées](#)

Création d'une connexion Azure Cosmos DB

Prérequis :

- Dans Azure, vous devez identifier ou générer une clé de base de données Azure Cosmos à utiliser par AWS Glue, `cosmosKey`. Pour plus d'informations, consultez la section [Accès sécurisé aux données dans Azure Cosmos DB](#) dans la documentation Azure.

Pour configurer une connexion à Azure Cosmos DB :

1. Dans AWS Secrets Manager, créez un secret à l'aide de votre clé de base de données Azure Cosmos. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret `secretName` pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé `spark.cosmos.accountKey` contenant la valeur. `cosmosKey`

2. Dans la AWS Glue console, créez une connexion en suivant les étapes décrites dans [the section called “Ajouter une AWS Glue connexion”](#). Après avoir créé la connexion, conservez le nom de la connexion pour une utilisation future dans AWS Glue. *connectionName*
 - Lorsque vous sélectionnez un type de connexion, sélectionnez Azure Cosmos DB.
 - Lorsque vous sélectionnez un AWS secret, fournissez *secretName*.

Création d'un nœud source Azure Cosmos DB

Prérequis

- Une connexion AWS Glue Azure Cosmos DB, configurée avec un AWS Secrets Manager secret, comme décrit dans la section précédente, [the section called “Création d'une connexion Azure Cosmos DB”](#).
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.
- Un conteneur Azure Cosmos DB pour NoSQL à partir duquel vous souhaitez lire. Vous aurez besoin des informations d'identification du conteneur.

Un conteneur Azure Cosmos pour NoSQL est identifié par sa base de données et son conteneur. Vous devez fournir les noms de base de données et de conteneur lorsque vous vous connectez à l'API Azure Cosmos pour NoSQL. *cosmosDBName cosmosContainerName*

Ajout d'une source de données Azure Cosmos DB

Pour ajouter un nœud Source de données – Azure Cosmos DB :

1. Choisissez la connexion pour votre source de données Azure Cosmos DB. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Créer une connexion Azure Cosmos DB. Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion Azure Cosmos DB”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Choisissez le nom de la base de données Cosmos DB : indiquez le nom de la base de données à partir de laquelle vous souhaitez lire *cosmosDBName*.
3. Choisissez Azure Cosmos DB Container : indiquez le nom du conteneur à partir duquel vous souhaitez lire *cosmosContainerName*.

4. Choisissez éventuellement la Requête personnalisé Azure Cosmos DB : fournissez une requête SQL SELECT pour récupérer des informations spécifiques à partir d'Azure Cosmos DB.
5. Dans les Propriétés Azure Cosmos personnalisées, saisissez les paramètres et les valeurs nécessaires.

Création d'un nœud cible Azure Cosmos DB

Prérequis

- Une connexion AWS Glue Azure Cosmos DB, configurée avec un AWS Secrets Manager secret, comme décrit dans la section précédente, [the section called “Création d'une connexion Azure Cosmos DB”](#).
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.
- Une table Azure Cosmos DB dans laquelle vous souhaitez écrire. Vous aurez besoin des informations d'identification du conteneur. Vous devez créer le conteneur avant d'appeler la méthode de connexion.

Un conteneur Azure Cosmos pour NoSQL est identifié par sa base de données et son conteneur. Vous devez fournir les noms de base de données et de conteneur lorsque vous vous connectez à l'API Azure Cosmos pour NoSQL. *cosmosDBName cosmosContainerName*

Ajout d'une cible de données Azure Cosmos DB

Pour ajouter un nœud Cible de données – Azure Cosmos DB :

1. Choisissez la connexion pour votre source de données Azure Cosmos DB. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Créer une connexion Azure Cosmos DB. Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion Azure Cosmos DB”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Choisissez le nom de la base de données Cosmos DB : indiquez le nom de la base de données à partir de laquelle vous souhaitez lire *cosmosDBName*.
3. Choisissez Azure Cosmos DB Container : indiquez le nom du conteneur à partir duquel vous souhaitez lire *cosmosContainerName*.

4. Dans les Propriétés Azure Cosmos personnalisées, saisissez les paramètres et les valeurs nécessaires.

Options avancées

Vous pouvez fournir des options avancées lors de la création d'un nœud Azure Cosmos DB. Ces options sont les mêmes que celles disponibles lors de la programmation AWS Glue de scripts Spark.

Consultez [the section called “Connexions Azure Cosmos DB”](#).

Connexion à Azure SQL dans AWS Glue Studio

AWS Glue fournit un support intégré pour Azure SQL. AWS Glue Studio fournit une interface visuelle pour se connecter à Azure SQL, créer des tâches d'intégration de données et les exécuter sur AWS Glue Studio environnement d'exécution Spark sans serveur.

Rubriques

- [Création d'une connexion Azure SQL](#)
- [Création d'un nœud source Azure SQL](#)
- [Création d'un nœud cible Azure SQL](#)
- [Options avancées](#)

Création d'une connexion Azure SQL

Pour vous connecter à Azure SQL depuis AWS Glue, vous devez créer et stocker vos informations d'identification Azure SQL dans un AWS Secrets Manager secret, puis associer ce secret à une AWS Glue connexion Azure SQL.

Pour configurer une connexion à Azure SQL :

1. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification Azure SQL. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé `user` contenant la valeur. *azuresqlUsername*

- Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé password contenant la valeur. *azuresqlPassword*
2. Dans la AWS Glue console, créez une connexion en suivant les étapes décrites dans [the section called “Ajouter une AWS Glue connexion”](#). Après avoir créé la connexion, conservez le nom de la connexion pour une utilisation future dans AWS Glue. *connectionName*
- Lorsque vous sélectionnez un type de connexion, sélectionnez Azure SQL.
 - Lorsque vous fournissez une URL Azure SQL, fournissez une URL de point de terminaison JDBC.

La URL doit avoir le format suivant :

`jdbc:sqlserver://databaseServerName:databasePort;databaseName=azuresqlDBName`

AWS Glue nécessite les propriétés d'URL suivantes :

- `databaseName` – une base de données par défaut dans Azure SQL à laquelle se connecter.

Pour plus d'informations sur JDBC URLs pour Azure SQL Managed Instances, consultez la documentation [Microsoft](#).

- Lorsque vous sélectionnez un AWS secret, fournissez *secretName*.

Création d'un nœud source Azure SQL

Prérequis

- Une connexion AWS Glue Azure SQL, configurée avec un AWS Secrets Manager secret, comme décrit dans la section précédente, [the section called “Création d'une connexion Azure SQL”](#).
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.
- Une table SQL Azure que vous souhaitez lire, *tableName*.

Une table Azure SQL est identifiée par sa base de données, son schéma et son nom de table. Vous devez fournir le nom de la base de données et le nom de la table lorsque vous vous connectez à Azure SQL. Vous devez également fournir le schéma s'il n'est pas « public » par défaut. La base de données est fournie via une propriété URL dans *connectionName*, un schéma et un nom de table via `ledbtable`.

Ajout d'une source de données Azure SQL

Pour ajouter un nœud Source de données – Azure SQL :

1. Choisissez la connexion pour votre source de données Azure SQL. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Créer une connexion Azure SQL. Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion Azure SQL”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Choisissez une option Source Azure SQL :
 - Choisissez une seule table : accéder à toutes les données à partir d'une seule table.
 - Saisir une requête personnalisée : accéder à un jeu de données à partir de plusieurs tables en fonction de votre requête personnalisée.
3. Si vous avez choisi une seule table, entrez *tableName*.

Si vous avez choisi Saisir une requête personnalisée, saisissez une requête TransactSQL SELECT.

4. Dans les Propriétés Azure SQL personnalisées, saisissez les paramètres et les valeurs nécessaires.

Création d'un nœud cible Azure SQL

Prérequis

- Une connexion AWS Glue Azure SQL, configurée avec un AWS Secrets Manager secret, comme décrit dans la section précédente, [the section called “Création d'une connexion Azure SQL”](#).
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.
- Une table SQL Azure dans laquelle vous souhaitez écrire, *tableName*.

Une table Azure SQL est identifiée par sa base de données, son schéma et son nom de table. Vous devez fournir le nom de la base de données et le nom de la table lorsque vous vous connectez à Azure SQL. Vous devez également fournir le schéma s'il n'est pas « public » par défaut. La base de données est fournie via une propriété d'URL dans *connectionName*, un schéma et un nom de table via *ledbtable*.

Ajout d'une cible de données Azure SQL

Pour ajouter un nœud Cible de données – Azure SQL :

1. Choisissez la connexion pour votre source de données Azure SQL. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Créer une connexion Azure SQL. Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion Azure SQL”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Configurez le nom de la table en fournissant *tableName*.
3. Dans les Propriétés Azure SQL personnalisées, saisissez les paramètres et les valeurs nécessaires.

Options avancées

Vous pouvez fournir des options avancées lors de la création d'un nœud Azure SQL. Ces options sont les mêmes que celles disponibles lors de la programmation AWS Glue de scripts Spark.

Consultez [the section called “Connexions Azure SQL”](#).

Connexion à Blackbaud Raiser's Edge NXT

Blackbaud Raiser's Edge NXT est une solution logicielle complète de collecte de fonds et de gestion des donateurs basée sur le cloud conçue spécifiquement pour les organisations à but non lucratif et l'ensemble de la communauté du bien social. Ce connecteur repose sur l'API SKY de Blackbaud Raiser's Edge NXT et fournit des opérations pour aider à gérer les entités présentes dans le Raisers Edge NXT.

Rubriques

- [AWS Glue support pour Blackbaud Raiser's Edge NXT](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Blackbaud Raiser's Edge NXT](#)
- [Configuration des connexions Edge NXT de Blackbaud Raiser](#)
- [Lecture à partir des entités Blackbaud Raiser's Edge NXT](#)
- [Options de connexion Edge NXT de Blackbaud Raiser](#)

- [Limites de Blackbaud Raiser's Edge NXT](#)

AWS Glue support pour Blackbaud Raiser's Edge NXT

AWS Glue prend en charge Blackbaud Raiser's Edge NXT comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données depuis Blackbaud Raiser's Edge NXT.

Soutenu en tant que cible ?

Non.

Versions de l'API Blackbaud Raiser's Edge NXT prises en charge

Les versions suivantes de l'API Blackbaud Raiser's Edge NXT sont prises en charge :

- v1

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Blackbaud Raiser's Edge NXT

Avant de pouvoir AWS Glue transférer des données depuis Blackbaud Raiser's Edge NXT, vous devez répondre aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un compte Blackbaud Raiser's Edge NXT.
- Vous avez généré un jeton d'accès sur votre compte Blackbaud Raiser's Edge NXT avec l'étendue de lecture/écriture appropriée assignée pour accéder au. APIs Pour plus d'informations, consultez la section [Autorisation](#).

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Blackbaud Raiser's Edge NXT.

Configuration des connexions Edge NXT de Blackbaud Raiser

Blackbaud Raiser's Edge NXT prend en charge le type de subvention AUTHORIZATION_CODE pour. OAuth2

- Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers un serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. La AWS Glue console redirige l'utilisateur vers Blackbaud Raiser's Edge NXT où il doit se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Blackbaud Raiser's Edge NXT.
- Les utilisateurs peuvent choisir de créer leur propre application connectée dans Blackbaud Raiser's Edge NXT et de fournir leur propre identifiant client, clé d'abonnement et URL d'instance lors de la création de connexions via la console. AWS Glue Dans ce scénario, ils seront toujours redirigés vers Blackbaud Raiser's Edge NXT pour se connecter et autoriser AWS Glue l'accès à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- [Pour consulter la documentation publique de Blackbaud Raiser's Edge NXT sur la création d'une application connectée pour le OAuth flux de code d'autorisation, voir Autorisation.](#)

Pour configurer une connexion Blackbaud Raiser's Edge NXT :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir la clé API de l'application connectée avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
 - b. Remarque : vous devez créer un secret pour vos connexions dans AWS Glue.
1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez une source de données, sélectionnez Blackbaud Raiser's Edge NXT.
 - b. Indiquez le INSTANCE_URL compte Blackbaud Raiser's Edge NXT auquel vous souhaitez vous connecter.
 - c. Fournissez l'application client gérée par l'utilisateur `clientId`.
 - d. Fournissez la clé d'abonnement associée à votre compte.
 - e. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- f. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
- g. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture à partir des entités Blackbaud Raiser's Edge NXT

Prérequis

Un objet Blackbaud Raiser's Edge NXT à partir duquel vous souhaitez lire. Vous aurez besoin du nom de l'objet.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Adresse du constituant	Oui	Oui	Non	Oui	Oui

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Éducation constituante	Oui	Oui	Non	Oui	Oui
Adresse e-mail du constituant	Oui	Oui	Non	Oui	Oui
Téléphone du constituant	Oui	Oui	Non	Oui	Oui
Note constitutive	Oui	Oui	Non	Oui	Oui
Relation constituante	Oui	Oui	Non	Oui	Oui
Présence en ligne du constituant	Oui	Oui	Non	Oui	Oui
Opportunité	Oui	Oui	Non	Oui	Oui
Appel	Oui	Oui	Non	Oui	Oui
Campagne	Oui	Oui	Non	Oui	Oui
Fonds	Oui	Oui	Non	Oui	Oui
Package	Oui	Oui	Non	Oui	Oui
Gift Batch	Oui	Oui	Non	Oui	Non
Participant à l'événement	Oui	Oui	Oui	Oui	Oui

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Mission de collecte de fonds constituante	Non	Non	Non	Oui	Non
Cadeau	Oui	Oui	Oui	Oui	Oui
Membres	Oui	Oui	Non	Oui	Oui
Action	Oui	Oui	Non	Oui	Non
Constituant	Oui	Oui	Oui	Oui	Oui
Biens constitutifs	Oui	Oui	Non	Oui	Oui
Événement	Oui	Oui	Oui	Oui	Oui
Champ personnalisé pour les cadeaux	Oui	Oui	Non	Oui	Oui

Exemple :

```
blackbaud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="BLACKBAUD",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v1",
        "SUBSCRIPTION_KEY": <Subscription key associated with one's developer account>
    }
)
```

Détails de l'entité et du champ Blackbaud Raiser's Edge NXT

Pour plus d'informations sur les entités et les détails des champs, voir :

- [Action](#)
- [Constituant](#)
- [Adresse du constituant](#)
- [Adhésion constituante](#)
- [Mission de collecte de fonds constituante](#)
- [Éducation constituante](#)
- [Adresse e-mail du constituant](#)
- [Téléphone du constituant](#)
- [Note constitutive](#)
- [Présence en ligne du constituant](#)
- [Relation constituante](#)
- [Événement](#)
- [Participant à l'événement](#)
- [Appel](#)
- [Campagne](#)
- [Fonds](#)
- [Package](#)
- [Cadeau](#)
- [Champ personnalisé pour les cadeaux](#)
- [Gift Batch](#)
- [Opportunité](#)
- [Codes constitutifs](#)

Note

Les types de données Struct et List sont convertis en type de données String, et le type de DateTime données est converti en Timestamp dans la réponse des connecteurs.

Requêtes de partitionnement

Partitionnement basé sur le terrain :

Blackbaud Raiser's Edge NXT ne prend pas en charge le partitionnement basé sur les champs ou les enregistrements.

Partitionnement basé sur des enregistrements :

Vous pouvez fournir l'option Spark supplémentaire NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ce paramètre, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

Dans le partitionnement basé sur les enregistrements, le nombre total d'enregistrements présents est demandé à partir de l'API Edge NXT de Blackbaud Raiser, et il est divisé par le nombre fourni. NUM_PARTITIONS Le nombre d'enregistrements qui en résulte est ensuite extrait simultanément par chaque sous-requête.

- NUM_PARTITIONS: le nombre de partitions.

Exemple :

```
blackbaud_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="BLACKBAUD",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "entityName",  
        "API_VERSION": "v1",  
        "NUM_PARTITIONS": "2",  
        "SUBSCRIPTION_KEY": "<Subscription key associated with one's developer account>"  
    }  
)
```

Options de connexion Edge NXT de Blackbaud Raiser

Les options de connexion pour Blackbaud Raiser's Edge NXT sont les suivantes :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Blackbaud Raiser's Edge NXT.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Rest Edge NXT de Blackbaud Raiser que vous souhaitez utiliser.

- `SELECTED_FIELDS(Liste<String>)` - Par défaut : vide (`SELECT *`). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- `FILTER_PREDICATE(String)` - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- `QUERY(String)` - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- `NUM_PARTITIONS(Entier)` - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire. Exemple de valeur : 10.
- `SUBSCRIPTION_KEY(String)` - (Obligatoire) Par défaut : vide. Utilisé pour la lecture. Clé d'abonnement associée à son compte développeur.

Limites de Blackbaud Raiser's Edge NXT

Voici les limitations ou remarques relatives à Blackbaud Raiser's Edge NXT :

- Le SaaS ne prend en charge que l'`EQUAL_TO` opérateur, qui renvoie les résultats créés ou modifiés à la date spécifiée ou après cette date. De plus, le champ « id » est un type de données String. Il n'y a pas non plus d'identification des champs non nullables. Par conséquent, le partitionnement basé sur les champs n'est pas pris en charge.
- L'attraction incrémentielle n'est prise en charge par l'Evententité qu'avec des fréquences quotidiennes, mensuelles et hebdomadaires.
- L'entité Constituante Fundraiser Assignment renvoie un maximum de 20 enregistrements.
- Partitionnement basé sur des enregistrements :
 - Non pris en charge par Action les Gift Batch entités Constituent Fundraiser Assignment ou.
 - Le partitionnement basé sur des enregistrements avec le prédicat de filtre n'est pris en charge que par les entités et. Event Event Participant Si un prédicat de filtre est utilisé avec d'autres entités prises en charge basées sur des enregistrements, une exception sera émise.
- Dans l'Gift Custom Fieldentité, le champ « valeur » doit être utilisé conjointement avec le champ « catégorie », faute de quoi une réponse non filtrée sera envoyée. Ainsi, pour obliger l'utilisateur à saisir le champ « catégorie » lors du filtrage avec le champ « valeur », une exception sera émise si l'exigence susmentionnée n'a pas été respectée.
- Les `last_modified` champs `date_added` et de toutes les entités applicables ne prennent en charge aucun opérateur comparatif. Ils ne prennent en charge que l'opérateur égal à. De plus, aucun champ ne peut être associé aux champs susmentionnés pour fournir une gamme

d'enregistrements. Par conséquent, ces champs sont uniquement interrogeables et ne peuvent pas prendre en charge le transfert incrémentiel.

- Le `added_by` champ de l'Gift Batchentité ne sera pas considéré comme filtrable car il risque de ne pas émettre les bons résultats.
- Il existe une latence d'environ 30 minutes pour que les enregistrements soient récupérés via le `GET Gift List` point de terminaison lors de l'insertion des données dans l'Giftentité.
- Support pour le transfert incrémentiel a été abandonné pour l'entité Gift en raison de limitations liées à la source de données.
- Il existe une latence de 10 minutes pour le champ de statut dans l'entité Opportunité.
- L'Fundraiser Assignmententité Constituent a pour entité dépendante. Le connecteur charge au maximum 5 000 personnes IDs parmi lesquelles choisir, afin d'éviter que la taille de réponse ne dépasse la taille de charge utile maximale autorisée.

Connexion à CircleCI

CircleCI est une plateforme d'intégration continue et de livraison continue. Votre compte CircleCI contient des données sur vos projets, vos pipelines, vos flux de travail, etc. Si vous êtes un utilisateur de CircleCI, vous pouvez vous connecter AWS Glue à votre compte CircleCI. Vous pouvez ensuite utiliser CircleCI comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre CircleCI AWS et des services ou d'autres applications prises en charge.

Rubriques

- [AWS Glue support pour CircleCI](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de CircleCI](#)
- [Configuration des connexions CircleCI](#)
- [Lecture à partir d'entités CircleCI](#)
- [Options de connexion CircleCI](#)
- [Limites de CircleCI](#)

AWS Glue support pour CircleCI

AWS Glue prend en charge CircleCI comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger les données de CircleCI.

Soutenu en tant que cible ?

Non.

Versions de l'API CircleCI prises en charge

Les versions suivantes de l'API CircleCI sont prises en charge :

- v2

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette

politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de CircleCI

Avant de pouvoir AWS Glue transférer des données depuis CircleCI, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un compte CircleCI qui contient les données que vous souhaitez transférer.
- Dans les paramètres utilisateur de votre compte, vous avez créé un jeton d'API personnel. Pour plus d'informations, consultez la section [Création d'un jeton d'API personnel](#).
- Vous fournissez le jeton d'API personnel à AWS Glue lors de la création de la connexion.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte CircleCI.

Configuration des connexions CircleCI

CircleCI prend en charge l'authentification personnalisée.

Pour configurer une connexion CircleCI :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir la clé API de l'application connectée avec `Circle-Token` comme clé.
 - b. Remarque : vous devez créer un secret pour vos connexions dans AWS Glue.
1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :

- a. Lorsque vous sélectionnez une source de données, sélectionnez CircleCI.
- b. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- c. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - d. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture à partir d'entités CircleCI

Prérequis

Un objet CircleCI que vous souhaitez lire. Vous aurez besoin du nom de l'objet.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Contexte	Oui	Non	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Métrique récapitulative de l'organisation	Oui	Non	Non	Oui	Non
Pipeline	Non	Non	Non	Oui	Non
Flux de travail d'un pipeline	Oui	Non	Non	Oui	Non
Branche du projet	Oui	Non	Non	Oui	Non
Projet Flaky Test	Non	Non	Non	Oui	Non
Métrique récapitulative du projet	Oui	Non	Non	Oui	Non
Planificateur	Non	Non	Non	Oui	Non
Série chronologique de Workflow Job	Oui	Non	Non	Oui	Non
Métrique et tendance du flux de travail	Oui	Non	Non	Oui	Non
Exécution récente du flux de travail	Oui	Non	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Mesure récapitulative du flux de travail	Oui	Non	Non	Oui	Non
Mesure de test du flux de travail	Oui	Non	Non	Oui	Non

Exemple :

```
circleci_read = glueContext.create_dynamic_frame.from_options(
    connection_type="circleci",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "context/e7ea2945-dccb-4205-b673-8391fe1b3a4c",
        "API_VERSION": "v2"
    }
)
```

Détails de l'entité et du champ CircleCI

Pour plus d'informations sur les entités et les détails des champs, voir :

- [Contextes](#)
- [Métriques récapitulatives du projet](#)
- [Série chronologique de Workflow Job](#)
- [Mesures récapitulatives de l'organisation](#)
- [Branches du projet](#)
- [Tests du projet Flaky](#)
- [Exécutions récentes du flux de travail](#)
- [Mesures récapitulatives du flux de travail](#)
- [Mesures et tendances du flux de travail](#)

- [Mesures de test du flux de travail](#)
- [Canalisations](#)
- [Flux de travail du pipeline](#)
- [Horaires](#)

Entités avec métadonnées statiques :

Entité	Champ	Type de données	Opérateurs pris en charge
Contexte	Créé à	Chaîne	
	ID	Chaîne	
	Nom	Chaîne	
	Type de propriétaire	Chaîne	EQUAL_TO
Métrique récapitulative de l'organisation	Tous les projets	Liste	
	Données de l'organisation	Struct	
	Données du projet d'organisation	Liste	
	Noms des projets	Chaîne	EQUAL_TO
	Fenêtre de rapport	Chaîne	EQUAL_TO
Pipeline	Branche	Chaîne	EQUAL_TO
	Créé à	Chaîne	
	Erreurs	Liste	
	ID	Chaîne	
	Nombre	Entier	

Entité	Champ	Type de données	Opérateurs pris en charge
	Projet Slug	Chaîne	
	État	Chaîne	
	Déclencheur	Struct	
	Paramètres du déclencheur	Struct	
	Mis à jour à	Chaîne	
	VCS	Struct	
Flux de travail d'un pipeline	Annulé par	Chaîne	
	Créé à	Chaîne	
	Erreur : Par	Chaîne	
	ID	Chaîne	
	Nom	Chaîne	
	ID du pipeline	Chaîne	
	Numéro de pipeline	Entier	
	Projet Slug	Chaîne	
	Commencé par	Chaîne	
	Statut	Chaîne	
	Arrêté à	Chaîne	
	Tag	Chaîne	
Branche du projet	Branches	Liste	

Entité	Champ	Type de données	Opérateurs pris en charge
Projet Flaky Test	Identifiant de l'organisation	Chaîne	
	ID du projet	Chaîne	
	Nom du flux de travail	Chaîne	EQUAL_TO
	Nom de classe	Chaîne	
	Fichier	Chaîne	
	Nom de la tâche	Chaîne	
	Numéro du job	Entier	
	Numéro de pipeline	Entier	
	Source	Chaîne	
	Nom du test	Chaîne	
	Temps perdu	Entier	
	Times Flaked	Entier	
	Flux de travail créé à	Chaîne	
	ID de flux de travail	Chaîne	
	Nom du flux de travail	Chaîne	
Métrique récapitulative du projet	Toutes les succursales	Liste	
	Tous les flux de travail	Liste	
	Branches	Chaîne	EQUAL_TO
	ID de l'organisation	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
Planificateur	Données du projet	Struct	
	ID du projet	Chaîne	
	Données de branche du flux de travail du projet	Liste	
	Données du flux de travail du projet	Liste	
	Fenêtre de rapport	Chaîne	EQUAL_TO
	Noms des flux de travail	Chaîne	EQUAL_TO
	Acteur	Struct	
	Créé à	Chaîne	
	Description	Chaîne	
	ID	Chaîne	
	Nom	Chaîne	
	Paramètres	Struct	
	Projet Slug	Chaîne	
	Horaire	Struct	
	Mis à jour à	Chaîne	
Série chronologique de Workflow Job	Branche	Chaîne	EQUAL_TO
	Granularité	Chaîne	EQUAL_TO

Entité	Champ	Type de données	Opérateurs pris en charge
	Max s'est terminé à	Chaîne	
	Métriques	Struct	
	Minimum commencé à	Chaîne	
	Nom	Chaîne	
	Date de début et de fin	DateTime	EQUAL_TO, ENTRE
	Horodatage	Chaîne	
Métrique et tendance du flux de travail	Toutes les succursales	Booléen	EQUAL_TO
	Branches	Chaîne	EQUAL_TO
	Métriques	Struct	
	Tendances	Struct	
	Noms des flux de travail	Liste	
Exécution récente du flux de travail	Toutes les branches	Booléen	EQUAL_TO
	Branche	Chaîne	EQUAL_TO
	Créé à	Chaîne	
	Crédits utilisés	Entier	
	Durée	Entier	
	ID	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
Mesure récapitulative du flux de travail	Est une approbation	Booléen	
	Date de début et de fin	DateTime	EQUAL_TO, ENTRE
	Statut	Chaîne	
	Arrêté à	Chaîne	
	Toutes les succursales	Booléen	EQUAL_TO
	Branche	Chaîne	EQUAL_TO
	Métriques	Struct	
	Nom	Chaîne	
	ID du projet	Chaîne	
	Fenêtre de rapport	Chaîne	EQUAL_TO
	Fin de fenêtre	Chaîne	
	Démarrage de la fenêtre	Chaîne	
Mesure de test du flux de travail	Nombre moyen de tests	Entier	
	Branche	Chaîne	EQUAL_TO
	Tests les plus ratés	Liste	
	Tests les plus ratés en supplément	Entier	
	Tests les plus lents	Liste	

Entité	Champ	Type de données	Opérateurs pris en charge
	Tests les plus lents en supplément	Entier	
	Tests	Liste	
	Nombre total de cycles d'essais	Entier	

Note

Les types de données Struct et List sont convertis en type de données String dans la réponse du connecteur.

Requêtes de partitionnement

CircleCI ne prend pas en charge le partitionnement basé sur les champs ou les enregistrements.

Options de connexion CircleCI

Les options de connexion pour CircleCI sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans CircleCI.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API CircleCI Rest que vous souhaitez utiliser.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

Limites de CircleCI

Voici les limitations ou remarques relatives à CircleCI :

- CircleCI ne prend en charge ni le partitionnement basé sur les champs ni sur le partitionnement basé sur les enregistrements.
- Les champs de filtre contenant un « - » (trait d'union) ne fonctionneront que s'ils sont encadrés par des backticks. Par exemple : `workflow-name` = « abc »
- Le type GitLab VCS ne peut pas être pris en charge car il n'existe aucun moyen programmatique de récupérer l'« ID de projet » requis pour le chemin de l'entité VCS GitLab.

Connexion à Datadog

Datadog est une plateforme de surveillance et d'analyse pour les applications à l'échelle du cloud, notamment les infrastructures, les applications, les services et les outils.

Rubriques

- [AWS Glue support pour Datadog](#)
- [Politiques contenant les opérations d'API pour la création et l'utilisation de connexions](#)
- [Configuration de Datadog](#)
- [Configuration des connexions Datadog](#)
- [Lecture depuis des entités Datadog](#)
- [Options de connexion Datadog](#)
- [Création d'un compte Datadog](#)
- [Limites](#)

AWS Glue support pour Datadog

AWS Glue supporte Datadog comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les jobs AWS Glue ETL pour interroger les données de Datadog.

Soutenu en tant que cible ?

Non.

Versions d'API Datadog prises en charge

- v1
- v2

Politiques contenant les opérations d'API pour la création et l'utilisation de connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode précédente, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#) — Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#) — Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Datadog

Avant de pouvoir AWS Glue effectuer un transfert depuis Datadog, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous possédez un compte Datadog avec DD-API-KEY et DD-APPLICATION-KEY Pour plus d'informations sur la création d'un compte, consultez [Création d'un compte Datadog](#).
- Votre compte Datadog dispose d'un accès à l'API avec une licence valide.

Datadog prend en charge les six suivants. URLs Tous les clients d'API Datadog sont configurés par défaut pour utiliser le site US1 Datadog. APIs Si vous êtes sur le site européen de Datadog, vous devez sélectionner l'URL <https://api.datadoghq.eu> avec le DD-API-KEY et du site européen DD-APPLICATION-KEY de Datadog pour accéder au. APIs De même, pour les autres sites, vous devez sélectionner le DD-API-KEY and DD-APPLICATION-KEY correspondant URLs avec le site concerné.

- US1 URL de l'API — <https://api.datadoghq.com> <https://api.datadoghq.com>
- URL de l'API de l'UE — <https://api.datadoghq.eu>
- US3 URL de l'API — <https://api.us3.datadoghq.com>
- US5 URL de l'API — <https://api.us5.datadoghq.com>
- URL DE L'API S1-FED — <https://api.ddog-gov.com>
- URL de l'API pour le Japon — <https://api.ap1.datadoghq.com>

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Datadog.

Configuration des connexions Datadog

Datadog prend en charge l'authentification personnalisée. Voici les étapes à suivre pour configurer la connexion Datadog :

Pour configurer une connexion Datadog, procédez comme suit :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :

Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec **API_KEY** et **APPLICATION_KEY** sous forme de clés.

 Note

Il est indispensable de créer un secret par connexion AWS Glue.

2. Dans AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Datadog.
 - b. Indiquez le Instance_Url Datadog auquel vous souhaitez vous connecter.
 - c. Sélectionnez le rôle IAM pour lequel AWS Glue vous pouvez assumer et qui dispose des autorisations nécessaires pour effectuer les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture depuis des entités Datadog

Prérequis

Un objet Datadog dont vous souhaitez lire un extrait. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Séries chronologiques Metrics	Oui	Non	Non	Oui	Non
Requêtes de journal	Oui	Oui	Oui	Oui	Non

Exemple

```
Datadog_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="datadog",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "log-queries",  
        "API_VERSION": "v2",  
        "INSTANCE_URL": "https://api.datadoghq.com",  
        "FILTER_PREDICATE": "from = `2023-10-03T09:00:26Z`"  
    }  
)
```

Informations sur les entités et les champs Datadog

Entité	Champ	Type de données	Opérateurs pris en charge
Séries chronologiques Metrics	error	Chaîne	NA

Entité	Champ	Type de données	Opérateurs pris en charge
	aggr	Chaîne	NA
	attributs	Struct	NA
	display_name	Chaîne	NA
	end	DateTime	NA
	expression	Chaîne	NA
	interval	Entier	NA
	longueur	Entier	NA
	métrique	Chaîne	NA
	liste de points	Liste	NA
	index_requête	Entier	NA
	scope	Chaîne	NA
	démarrer	DateTime	NA
	tag_set	Liste	NA
	unité	Struct	NA
	de_à_date	DateTime	BETWEEN
	query	Chaîne	EQUAL_TO
	status	Chaîne	NA
	type	Chaîne	NA
	hôte	Chaîne	NA
Requêtes de journal	id	Chaîne	NA

Entité	Champ	Type de données	Opérateurs pris en charge
	attributs	Struct	NA
	timestamp	DateTime	NA
	type	Chaîne	NA
	from	DateTime	ENTRE, EQUAL_TO
	index	Liste	EQUAL_TO
	niveau de stockage	Chaîne	EQUAL_TO
	query	Chaîne	EQUAL_TO

Options de connexion Datadog

Voici les options de connexion pour Datadog :

- **ENTITY_NAME**(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Datadog.
- **API_VERSION**(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Rest de Datadog que vous souhaitez utiliser. v1 la version prend en charge `metrics-timeseries` l'entité tandis que v2 la version prend en charge `log-queries` l'entité.
- **INSTANCE_URL**(Chaîne) — (Obligatoire) Utilisé pour la lecture. URL de l'instance Datadog. L'URL de l'instance Datadog varie selon les régions.
- **SELECTED_FIELDS**(Liste<String>) — Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) — Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) — Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

Création d'un compte Datadog

1. Accédez à <https://www.datadoghq.com/>.

2. Choisissez GET STARTED FREE.
3. Entrez les informations requises et inscrivez-vous.
4. Installez le programme d'installation de l'agent Datadog comme suggéré.
5. Assurez-vous que le compte est enregistré auprès d'une organisation valide (dans la liste disponible) disposant d'un abonnement Datadog actif.
6. Une fois connecté à votre compte Datadog, survolez votre nom d'utilisateur dans le coin supérieur droit pour afficher les détails des clés :
 - a. Pour obtenir votre clé d'API, choisissez API Keys.
 - b. Pour obtenir votre clé d'application, choisissez Application Keys.

Limites

Les limites du connecteur Datadog sont les suivantes :

- Datadog ne prend en charge ni le partitionnement basé sur les champs ni sur le partitionnement basé sur les enregistrements.
- `fromest` un paramètre de filtre obligatoire pour `Log Queries` l'entité.
- `from_to_dateet query` sont des paramètres de filtre obligatoires pour `Metrics Timeseries` l'entité.

Connexion à Docusign Monitor

Docusign Monitor aide les entreprises à protéger leurs accords grâce au suivi des round-the-clock activités. L'API Monitor fournit ces informations de suivi des activités directement aux outils de sécurité ou de visualisation des données existants, ce qui permet aux équipes de détecter les activités non autorisées, d'enquêter sur les incidents et de réagir rapidement aux menaces vérifiées. Il offre également la flexibilité dont les équipes de sécurité ont besoin pour personnaliser les tableaux de bord et les alertes afin de répondre aux besoins spécifiques de l'entreprise.

Rubriques

- [AWS Glue support pour Docusign Monitor](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Docusign Monitor](#)
- [Configuration des connexions Docusign Monitor](#)

- [Lecture depuis les entités Docusign Monitor](#)
- [Options de connexion à Docusign Monitor](#)
- [Limites de Docusign Monitor](#)

AWS Glue support pour Docusign Monitor

AWS Glue prend en charge Docusign Monitor comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données depuis Docusign Monitor.

Soutenu en tant que cible ?

Non.

Versions de l'API Docusign Monitor prises en charge

Les versions suivantes de l'API Docusign Monitor sont prises en charge :

- v2.0

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
    }
  ],
}
```

```
        "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Docusign Monitor

Avant de pouvoir AWS Glue transférer des données depuis Docusign Monitor vers des destinations prises en charge, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous disposez d'un compte Docusign sur lequel vous pouvez utiliser le produit Docusign Software dans Docusign Monitor.
- Dans la console de développement de votre compte Docusign, vous avez créé une application d'intégration OAuth 2.0 pour AWS Glue

Cette application fournit les informations d'identification du client qui AWS Glue permettent d'accéder à vos données en toute sécurité lorsqu'elle passe des appels authentifiés vers votre compte. Pour plus d'informations, consultez la [OAuth version 2.0](#) dans la documentation de Docusign Monitor.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Docusign Monitor.

Configuration des connexions Docusign Monitor

Docusign Monitor prend en charge le type de subvention `AUTHORIZATION_CODE`.

- Ce type de subvention est considéré comme tridimensionnel OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console.
- Les utilisateurs peuvent choisir de créer leur propre application connectée dans Docusign Monitor et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Docusign Monitor pour se connecter et autoriser l'accès AWS Glue à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- Pour consulter la documentation publique de Docusign Monitor sur la création d'une application connectée pour le OAuth flux de code d'autorisation, consultez [Docusign OAuth Connect](#).

Pour configurer une connexion Docusign Monitor :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir la clé API de l'application connectée avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
 - b. Remarque : vous devez créer un secret pour vos connexions dans AWS Glue.
1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Sous Connexions, choisissez Créer une connexion.
 - b. Lorsque vous sélectionnez une source de données, sélectionnez Docusign Monitor.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{  
  "Version": "2012-10-17",
```

```
"Statement": [
  {
    "Effect": "Allow",
    "Action": [
      "secretsmanager:DescribeSecret",
      "secretsmanager:GetSecretValue",
      "secretsmanager:PutSecretValue",
      "ec2:CreateNetworkInterface",
      "ec2:DescribeNetworkInterface",
      "ec2>DeleteNetworkInterface",
    ],
    "Resource": "*"
  }
]
```

- d. Fournissez l'application client gérée par l'utilisateur ClientId de l'application Docusign Monitor.
 - e. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - f. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture depuis les entités Docusign Monitor

Prérequis

Un objet Docusign Monitor que vous souhaitez lire.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Surveillance des données	Oui	Oui	Non	Oui	Non

Exemple :

```

docusignmonitor_read = glueContext.create_dynamic_frame.from_options(
    connection_type="docusign_monitor",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "monitoring-data",
        "API_VERSION": "v2.0"
    }
)

```

Détails des entités et des champs de Docusign Monitor

Entités avec métadonnées statiques :

Entité	Champ	Type de données	Opérateurs pris en charge
Surveillance des données	timestamp	DateTime	N/A
	eventId	Chaîne	N/A
	application	Chaîne	N/A
	environment	Chaîne	N/A
	site	Chaîne	N/A
	Trace Token	Chaîne	N/A
	ID de l'organisation	Chaîne	N/A
	accountId	Chaîne	N/A
	userId	Chaîne	N/A
	objet	Chaîne	N/A
	action	Chaîne	N/A
	property	Chaîne	N/A
	field	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	result	Chaîne	N/A
	IntegratorKey	Chaîne	N/A
	Visible par le client	Chaîne	N/A
	version	Chaîne	N/A
	userAgent	Chaîne	N/A
	userAgentClientInfos	Struct	N/A
	ipAddress	Chaîne	N/A
	ipAddressLocation	Struct	N/A
	data	Chaîne	N/A
	source	Chaîne	N/A
	latitude	Double	N/A
	longitude	Double	N/A
	city	Chaîne	N/A
	state	Chaîne	N/A
	country	Chaîne	N/A
	usUserMemberOfDomain	Booléen	N/A
	affectedUsersIsMemberOfDomain	Booléen	N/A
	État du proxy	Chaîne	N/A
	Type de proxy	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Niveau de proxy	Chaîne	N/A
	referencedUserId	Chaîne	N/A
	appareil	Chaîne	N/A
	navigateur	Chaîne	N/A
	curseur	DateTime	EQUAL_TO

Requêtes de partitionnement

Docusign Monitor ne prend en charge ni le partitionnement basé sur les champs ni sur le partitionnement basé sur les enregistrements.

Options de connexion à Docusign Monitor

Les options de connexion pour Docusign Monitor sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Docusign Monitor.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Rest de Docusign Monitor que vous souhaitez utiliser.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.

Limites de Docusign Monitor

Voici les limitations ou remarques relatives à Docusign Monitor :

- Lorsqu'un filtre est appliqué à l'aide du `cursor` champ, l'API récupère les enregistrements des sept prochains jours à compter de la date spécifiée.

- Si aucun filtre n'est fourni, l'API récupère les enregistrements des sept jours précédents à compter de la date actuelle de la demande d'API.
- Docusign Monitor ne prend en charge ni le partitionnement basé sur les champs ni sur le partitionnement basé sur les enregistrements.
- Docusign Monitor ne prend pas en charge la fonctionnalité Order By.

Connexion à Domo

Domo est un outil de tableau de bord basé sur le cloud. Avec la plate-forme d'applications d'entreprise de Domo, les bases dont vous avez besoin pour étendre Domo sont en place, afin que vous puissiez créer vos solutions personnalisées plus rapidement.

Rubriques

- [AWS Glue support pour Domo](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Domo](#)
- [Configuration des connexions Domo](#)
- [Lecture depuis les entités Domo](#)
- [Options de connexion Domo](#)
- [Limites de Domo](#)

AWS Glue support pour Domo

AWS Glue supporte Domo comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Domo.

Soutenu en tant que cible ?

Non.

Versions de l'API Domo prises en charge

Les versions suivantes de l'API Domo sont prises en charge :

- v1

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Domo

Avant de pouvoir transférer des AWS Glue données depuis Domo vers des destinations prises en charge, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un compte Domo activé pour accéder à l'API.
- Vous avez une application dans votre compte de développeur Domo qui fournit les informations d'identification du client qui permettent d' AWS Glue accéder à vos données en toute sécurité lorsqu'il passe des appels authentifiés vers votre compte. Pour de plus amples informations, veuillez consulter [Création d'une application pour développeurs Domo](#).

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Domo.

Création d'une application pour développeurs Domo

Pour obtenir l'ID client et le secret du client, vous devez créer un compte développeur.

1. Accédez à la [page de connexion du développeur Domo](#).
2. Choisissez Login (Connexion).
3. Indiquez le nom de domaine et cliquez sur Continuer.
4. Passez la souris sur Mon compte et choisissez Nouveau client.
5. Indiquez le nom et la description, sélectionnez l'étendue (« données ») et choisissez Créer.
6. Récupérez l'ID client et le secret client générés auprès du nouveau client créé.

Configuration des connexions Domo

Domo prend en charge le type de subvention CLIENT_CREDENTIALS pour. OAuth2

- Ce type de subvention est considéré comme bidimensionnel OAuth car seule l'application cliente s'authentifie auprès du serveur, sans aucune implication de l'utilisateur.
- Les utilisateurs peuvent choisir de créer leur propre application connectée dans Domo et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console.

- Pour consulter la documentation publique de Domo sur la création d'une application connectée pour le OAuth flux de code d'autorisation, consultez [OAuth Authentication](#).

Pour configurer une connexion Domo :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir le jeton d'accès à l'application connectée `client_id`, et `client_secret`.
 - b. Remarque : vous devez créer un secret pour vos connexions dans AWS Glue.
1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Sous Connexions, choisissez Créer une connexion.
 - b. Lorsque vous sélectionnez une source de données, sélectionnez Domo.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
- e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.

2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture depuis les entités Domo

Prérequis

Un objet Domo dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet, tel que l'ensemble de données ou les politiques d'autorisation des données. Le tableau suivant indique les entités prises en charge.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Ensemble de données	Oui	Oui	Oui	Oui	Oui
Politiques d'autorisation des données	Non	Non	Non	Oui	Non

Exemple :

```
Domo_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="domo",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "dataset",  
        "API_VERSION": "v1"  
    }  
)
```

Détails de l'entité et du champ Domo

Entités avec métadonnées statiques :

Entité	Champ	Type de données	Opérateurs pris en charge
Politiques d'autorisation des données	id	Long	N/A
	type	Chaîne	N/A
	name	Chaîne	N/A
	filtres	Liste	N/A
	utilisateurs	Liste	N/A
	Utilisateurs virtuels	Liste	N/A
	groups	Liste	N/A

Pour l'entité suivante, Domo fournit des points de terminaison permettant de récupérer les métadonnées de manière dynamique, afin que le support des opérateurs soit capturé au niveau du type de données de l'entité.

Entité	Type de données	Opérateurs pris en charge
Ensemble de données	Entier	=, !=, <, >, >=, <=
	Long	=, !=, <, >, >=, <=
	Chaîne	=, !=, CONTIENT
	Date	=, >, >=, <, <=, ENTRE
	DateTime	=, >, >=, <, <=, ENTRE
	Booléen	=, !=
	Double	=, !=, <, >, >=, <=
	Liste	N/A
	Struct	N/A

Requêtes de partitionnement

Partitionnement basé sur le terrain

Vous pouvez fournir les options supplémentaires de Spark

`PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, et `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur limite inférieure inclusive du champ de partition choisi.

Pour le `DateTime` champ, nous acceptons la valeur au format ISO.

Exemple de valeur valide :

```
"2023-01-15T11:18:39.205Z"
```

Pour le champ `Date`, nous acceptons la valeur au format ISO.

Exemple de valeur valide :

```
"2023-01-15"
```

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.

Exemple de valeur valide :

```
"2023-02-15T11:18:39.205Z"
```

- `NUM_PARTITIONS`: le nombre de partitions.

Les détails relatifs à la prise en charge des champs de partitionnement par entité sont présentés dans le tableau suivant :

Nom de l'entité	Champs de partitionnement	Type de données
Jeux de données	N'importe quel champ basé sur la date et l'heure [métadonnées dynamiques]	DateTime
	N'importe quel champ basé sur une date [métadonnées dynamiques]	Date

Exemple :

```
Domo_read = glueContext.create_dynamic_frame.from_options(
    connection_type="domo",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "dataset",
        "API_VERSION": "v1",
        "PARTITION_FIELD": "permissionTime"
        "LOWER_BOUND": "2023-01-15T11:18:39.205Z"
        "UPPER_BOUND": "2023-02-15T11:18:39.205Z"
        "NUM_PARTITIONS": "2"
    }
)
```

Partitionnement basé sur des enregistrements

Vous pouvez fournir l'option Spark supplémentaire NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ce paramètre, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

Dans le partitionnement basé sur les enregistrements, le nombre total d'enregistrements présents est demandé à Domo et divisé par le nombre fourni. NUM_PARTITIONS Le nombre d'enregistrements qui en résulte est ensuite extrait simultanément par chaque sous-requête.

Exemple :

```
Domo_read = glueContext.create_dynamic_frame.from_options(
    connection_type="domo",
    connection_options={
```

```
"connectionName": "connectionName",  
"ENTITY_NAME": "dataset",  
"API_VERSION": "v1",  
"NUM_PARTITIONS": "2"  
}
```

Options de connexion Domo

Les options de connexion pour Domo sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Domo.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Domo Rest que vous souhaitez utiliser.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour lire. Nombre de partitions à lire.

Limites de Domo

Les limitations ou remarques suivantes concernent Domo :

- En raison d'une limitation du SDK, le filtrage ne fonctionne pas comme prévu pour les champs interrogeables commençant par « _ » (par exemple : `_BATCH_ID`).
- En raison d'une limitation de l'API, le filtrage fonctionne à la date antérieure à la date que vous avez indiquée. Cela affecte également l'attraction incrémentielle. Pour contourner cette limitation, sélectionnez une date en fonction de votre fuseau horaire par rapport à l'UTC, afin d'obtenir les données correspondant à la date requise.

Connexion à Dynatrace

Dynatrace est une plateforme qui propose des outils d'analyse et d'automatisation pour une observabilité et une sécurité complètes. Elle est spécialisée dans la surveillance et l'optimisation des performances des applications, de l'infrastructure et de l'expérience utilisateur.

Rubriques

- [AWS Glue support pour Dynatrace](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Dynatrace](#)
- [Configuration des connexions Dynatrace](#)
- [Lecture depuis les entités Dynatrace](#)
- [Options de connexion Dynatrace](#)
- [Limites de Dynatrace](#)

AWS Glue support pour Dynatrace

AWS Glue prend en charge Dynatrace comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Dynatrace.

Soutenu en tant que cible ?

Non.

Versions de l'API Dynatrace prises en charge

Les versions suivantes de l'API Dynatrace sont prises en charge :

- v2

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Dynatrace

Avant de pouvoir AWS Glue transférer des données depuis Dynatrace, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un compte Dynatrace.
- Vous avez généré un jeton d'accès dans votre compte Dynatrace avec le champ de lecture/écriture approprié attribué pour accéder au. APIs Pour plus d'informations, consultez la section [Générer un jeton](#).

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Dynatrace.

Configuration des connexions Dynatrace

Dynatrace prend en charge l'authentification personnalisée.

Pour configurer une connexion Dynatrace :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir la clé API de l'application connectée avec *apiToken* comme clé.
 - b. Remarque : vous devez créer un secret pour vos connexions dans AWS Glue.
1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez une source de données, sélectionnez Dynatrace.
 - b. Indiquez le INSTANCE_URL compte Dynatrace auquel vous souhaitez vous connecter.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
```

```

    ],
    "Resource": "*"
  }
]
}

```

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture depuis les entités Dynatrace

Prérequis

Un objet Dynatrace dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet tel que « problème ».

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Problème	Oui	Oui	Oui	Oui	Non

Exemple :

```

Dynatrace_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Dynatrace",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "problem",
        "API_VERSION": "v2",
        "INSTANCE_URL": "https://[instanceName].live.dynatrace.com"
    }
)

```

Détails de l'entité et du champ Dynatrace :

Dynatrace fournit des points de terminaison permettant de récupérer les métadonnées de manière dynamique pour les entités prises en charge. Par conséquent, le support de l'opérateur est capturé au niveau du type de données.

Entité	Champ	Type de données	Opérateurs pris en charge
Problème	Entités concernées	Liste	EQUAL_TO
	Afficher l'ID	Chaîne	EQUAL_TO
	endTime	DateTime	
	Balises d'entité	Liste	
	Détails des preuves	Struct	
	Analyse d'impact	Struct	
	Niveau d'impact	Chaîne	EQUAL_TO
	Entités touchées	Liste	EQUAL_TO
	linkedProblemInfo	Struct	
	Zones de gestion	Liste	EQUAL_TO
	Filtres à problèmes	Liste	
	Commentaires récents	Struct	
	rootCauseEntity	Struct	EQUAL_TO
	ID du problème	Chaîne	EQUAL_TO
	Niveau de gravité	Chaîne	EQUAL_TO
	startTime	DateTime	BETWEEN
	status	Chaîne	EQUAL_TO

Entité	Champ	Type de données	Opérateurs pris en charge
	title	Chaîne	
	from	DateTime	EQUAL_TO, ENTRE
	problemFilterIds	Chaîne	EQUAL_TO
	problemFilterNames	Chaîne	EQUAL_TO
	managementZonelds	Chaîne	EQUAL_TO
	text	Chaîne	EQUAL_TO
	En cours de maintenance	Booléen	EQUAL_TO
	message	Chaîne	

Requêtes de partitionnement

Dynatrace ne prend pas en charge le partitionnement basé sur les champs ou les enregistrements.

Options de connexion Dynatrace

Les options de connexion pour Dynatrace sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Dynatrace.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Dynatrace Rest que vous souhaitez utiliser.
- **INSTANCE_URL**(String) - Utilisé pour la lecture. URL d'instance Dynatrace valide.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

Limites de Dynatrace

Voici les limitations ou remarques relatives à Dynatrace :

- Dynatrace ne prend en charge ni le partitionnement basé sur les champs ni sur le partitionnement basé sur les enregistrements.
- Pour la fonctionnalité Tout sélectionner, si vous fournissez le « champ » dans le filtre, le nombre d'enregistrements ne pourra pas dépasser 10 par page.
- La taille de page maximale prise en charge est de 500. Si vous sélectionnez l'un des champs [evidenceDetails, impactAnalysis, recentComments] lors de la création du flux, le nombre d'enregistrements par page sera défini par défaut à 10.

Connexion aux publicités Facebook

Facebook Ads est une puissante plateforme de publicité numérique utilisée par les entreprises de toutes tailles pour atteindre leur public cible et atteindre divers objectifs marketing. La plateforme permet aux annonceurs de créer des publicités personnalisées qui peuvent être affichées sur l'ensemble de la gamme d'applications et de services de Facebook, notamment Facebook et Messenger. Grâce à ses fonctionnalités de ciblage avancées, Facebook Ads permet aux entreprises d'atteindre des données démographiques, des centres d'intérêt, des comportements et des lieux spécifiques.

Rubriques

- [AWS Glue support pour Facebook Ads](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration des publicités Facebook](#)
- [Configuration des connexions Facebook Ads](#)
- [Lecture depuis les entités Facebook Ads](#)
- [Options de connexion à Facebook Ads](#)
- [Limitations et remarques relatives au connecteur Facebook Ads](#)

AWS Glue support pour Facebook Ads

AWS Glue prend en charge les publicités Facebook comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données provenant de Facebook Ads.

Soutenu en tant que cible ?

Non.

Versions de l'API Facebook Ads prises en charge

Les versions suivantes de l'API Facebook Ads sont prises en charge :

- v17.0
- version 18.0
- version 19.0
- version 20.0

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration des publicités Facebook

Avant de pouvoir AWS Glue transférer des données depuis Facebook Ads, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Les comptes Facebook Standard sont accessibles directement via Facebook.
- L'authentification de l'utilisateur est nécessaire pour générer le jeton d'accès.
- Le connecteur du SDK Facebook Ads implémentera le OAuth flux de jetons d'accès utilisateur.
- Nous utilisons OAuth2 .0 pour authentifier nos demandes d'API auprès de Facebook Ads. Cette authentification basée sur le Web s'inscrit dans le cadre de l'architecture Multi-Factor Authentication (MFA), qui est un sur-ensemble de la 2FA.
- L'utilisateur doit accorder des autorisations pour accéder aux points de terminaison. Pour accéder aux données de l'utilisateur, l'autorisation du point de terminaison est gérée par le biais [d'autorisations](#) et de [fonctionnalités](#).

Obtenir des informations d'identification OAuth 2.0

Pour obtenir des informations d'identification d'API afin de pouvoir effectuer des appels authentifiés vers votre instance, consultez l'[API REST](#) dans le guide du développeur de Facebook Ads.

Configuration des connexions Facebook Ads

Facebook Ads prend en charge le type de subvention AUTHORIZATION_CODE pour OAuth2

- Ce type de subvention est considéré comme tridimensionnel OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console.
- Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans Facebook Ads et de fournir leur propre identifiant client et leur secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Facebook Ads pour se connecter et autoriser AWS Glue l'accès à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'accès. Un jeton d'utilisateur système expirant est valide pendant 60 jours à compter de la date de génération ou d'actualisation. Pour assurer la continuité, le développeur doit actualiser le jeton d'accès dans les 60 jours. Ne pas le faire entraîne la perte du jeton d'accès et oblige le développeur à en obtenir un nouveau pour retrouver l'accès à l'API. Voir [Actualiser le jeton d'accès](#).
- Pour consulter la documentation relative aux publicités Facebook publiques sur la création d'une application connectée pour le OAuth flux de code d'autorisation, consultez la section [Utiliser la OAuth version 2.0 pour accéder à Google APIs](#) dans le guide Google pour les développeurs.

Pour configurer une connexion à Facebook Ads, procédez comme suit :

1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Facebook Ads.
 - b. Indiquez INSTANCE_URL l'instance Facebook Ads à laquelle vous souhaitez vous connecter.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires à cet effet :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
```

```

        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
    ],
    "Resource": "*"
}
]
}

```

d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.

e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.

2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture depuis les entités Facebook Ads

Prérequis

Un objet Facebook Ads dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet. Les tableaux suivants indiquent les entités prises en charge.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Campagne	Oui	Oui	Non	Oui	Oui
Set de publicités	Oui	Oui	Non	Oui	Oui
Publicités	Oui	Oui	Non	Oui	Oui
Créatif publicitaire	Non	Oui	Non	Oui	Non
Insights - Compte	Non	Oui	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Comptes publicitaires	Oui	Oui	Non	Oui	Non
Insights - Publicité	Oui	Oui	Non	Oui	Oui
Perspectives - AdSet	Oui	Oui	Non	Oui	Oui
Insights - Campagne	Oui	Oui	Non	Oui	Oui

Exemple :

```
FacebookAds_read = glueContext.create_dynamic_frame.from_options(
    connection_type="FacebookAds",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v20.0"
    }
)
```

Détails de l'entité et du champ Facebook Ads

Pour plus d'informations sur les entités et les détails des champs, voir :

- [Compte publicitaire](#)
- [Campagne](#)
- [Set de publicités](#)
- [Annonce](#)
- [Créatif publicitaire](#)
- [Compte Insight Ad](#)
- [Publicités Insights](#)

- [Perspectives AdSets](#)
- [Campagnes Insights](#)

Pour plus d'informations, consultez la section [API marketing](#).

 Note

Les types de données Struct et List sont convertis en type de données String en réponse aux connecteurs.

Requêtes de partitionnement

Vous pouvez fournir les options supplémentaires de Spark `PARTITION_FIELD_LOWER_BOUND`, `UPPER_BOUND`, et `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur de limite inférieure inclusive du champ de partition choisi.

Pour le `DateTime` champ, nous acceptons le format d'horodatage Spark utilisé dans les requêtes SQL Spark.

Exemple de valeur valide :

```
"2022-01-01"
```

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`: le nombre de partitions.

Exemple :

```
FacebookADs_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="FacebookAds",  
    connection_options={  
        "connectionName": "connectionName",
```

```
"ENTITY_NAME": "entityName",  
"API_VERSION": "v20.0",  
"PARTITION_FIELD": "created_time"  
"LOWER_BOUND": "2022-01-01"  
"UPPER_BOUND": "2024-01-02"  
"NUM_PARTITIONS": "10"  
}
```

Options de connexion à Facebook Ads

Les options de connexion pour Facebook Ads sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans les publicités Facebook.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Facebook Ads Rest que vous souhaitez utiliser. Par exemple : v1.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour lire. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour lire. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour lire. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour lire. Nombre de partitions à lire.
- **TRANSFER_MODE**(String) - Par défaut : SYNC. Utilisé pour la lecture asynchrone.

Limitations et remarques relatives au connecteur Facebook Ads

Voici les limites ou remarques relatives au connecteur Facebook Ads :

- Comme Facebook Ads prend en charge les métadonnées dynamiques, tous les champs peuvent être interrogés. Tous les champs prennent en charge le filtrage et les enregistrements sont récupérés si les données sont disponibles, sinon Facebook renvoie une réponse à une mauvaise demande (400) avec un message d'erreur approprié.

- Le nombre d'appels d'une application est le nombre d'appels qu'un utilisateur peut passer pendant une période d'une heure continue (200 fois par le nombre d'utilisateurs). Pour plus de détails sur les limites de [taux](#), consultez les sections [Limites de taux](#) et [Limites de taux pour les cas d'utilisation professionnelle](#).

Connexion à Facebook Page Insights

Les pages Facebook permettent aux entreprises et aux autres groupes d'intérêt de créer des pages pour le réseau social Facebook.com. Les entreprises utilisent ces pages pour partager les heures d'ouverture, faire des annonces et interagir avec les clients en ligne. Si vous êtes un utilisateur de Facebook Page Insights, vous pouvez vous connecter AWS Glue à votre compte Facebook Page Insights. Vous pouvez utiliser Facebook Page Insights comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer les données de Facebook Page Insights vers AWS des services ou d'autres applications compatibles.

Rubriques

- [AWS Glue support pour Facebook Page Insights](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Facebook Page Insights](#)
- [Configuration des connexions à Facebook Page Insights](#)
- [Lecture à partir des entités Facebook Page Insights](#)
- [Options de connexion à Facebook Page Insights](#)
- [Limitations et remarques relatives au connecteur Facebook Page Insights](#)

AWS Glue support pour Facebook Page Insights

AWS Glue prend en charge Facebook Page Insights comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Facebook Page Insights.

Soutenu en tant que cible ?

Non.

Versions de l'API Facebook Page Insights prises en charge

Les versions suivantes de l'API Facebook Page Insights sont prises en charge :

- v17
- v18
- v19
- v20
- v21

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Facebook Page Insights

Avant de pouvoir AWS Glue transférer des données depuis Facebook Page Insights, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Les comptes Facebook Standard sont accessibles directement via Facebook.
- L'authentification de l'utilisateur est nécessaire pour générer le jeton d'accès.
- Le connecteur Facebook Page Insights implémente le OAuth flux de jetons d'accès utilisateur.
- Le connecteur utilise la valeur OAuth2 .0 pour authentifier nos demandes d'API auprès de Facebook Page Insights. Cela relève de l'architecture Multi-Factor Authentication (MFA), qui est un sur-ensemble de l'authentification à deux facteurs. Il s'agit d'une authentification basée sur le Web.
- L'utilisateur doit accorder des autorisations pour accéder aux points de terminaison. Pour accéder aux données de l'utilisateur, l'autorisation du point de terminaison est gérée par le biais d'autorisations et de fonctionnalités.

Configuration des connexions à Facebook Page Insights

Pour configurer une connexion à Facebook Page Insights, procédez comme suit :

1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Facebook Page Insights.
 - b. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{  
  "Version": "2012-10-17",
```

```

    "Statement": [
      {
        "Effect": "Allow",
        "Action": [
          "secretsmanager:DescribeSecret",
          "secretsmanager:GetSecretValue",
          "secretsmanager:PutSecretValue",
          "ec2:CreateNetworkInterface",
          "ec2:DescribeNetworkInterface",
          "ec2:DeleteNetworkInterface",
        ],
        "Resource": "*"
      }
    ]
  }
}

```

- c. Sélectionnez l'URL du code d'autorisation.
 - d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture à partir des entités Facebook Page Insights

Prérequis

Un objet Facebook Page Insights dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Contenu de la page	Oui	Non	Oui	Oui	Oui
Clics sur la page CTA	Oui	Non	Non	Oui	Oui

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Engagement sur la page	Oui	Non	Non	Oui	Oui
Impressions de pages	Oui	Non	Non	Oui	Oui
Publications de page	Oui	Non	Non	Oui	Oui
Engagement lié à la publication de	Non	Non	Non	Oui	Non
Réactions aux publications sur la page	Non	Non	Non	Oui	Non
Réactions sur les pages	Oui	Non	Non	Oui	Oui
Narrations	Oui	Non	Non	Oui	Oui
Démographie des utilisateurs de la page	Oui	Non	Non	Oui	Oui
Pages vues de vidéos	Oui	Non	Non	Oui	Oui
Pages vues	Oui	Non	Non	Oui	Oui

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Publications vidéo de la page	Oui	Non	Non	Oui	Oui
Pages	Non	Oui	Non	Oui	Non
Aliments	Oui	Oui	Non	Oui	Oui

Exemple :

```
facebookPageInsights_read = glueContext.create_dynamic_frame. from options(
    connection_type="facebookpageinsights",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v21"
    }
)
```

Détails du champ Facebook Page Insights :

Entité	Champ	Type de données	Opérateurs pris en charge
Contenu de la page	Nom	Chaîne	N/A
	Période	Période	EQUAL_TO
	Depuis	DateTime	EQUAL_TO
	Valeurs	Liste	N/A
	Title	Chaîne	N/A
	Description	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
Clics sur la page CTA	description_de_api_doc	Chaîne	N/A
	Id	Chaîne	N/A
	Nom	Chaîne	N/A
	Période	Période	EQUAL_TO
	Depuis	DateTime	EQUAL_TO
	Valeurs	Liste	N/A
	Title	Chaîne	N/A
	Description	Chaîne	N/A
Engagement sur la page	description_de_api_doc	Chaîne	N/A
	Id	Chaîne	N/A
	Nom	Chaîne	N/A
	Période	Période	EQUAL_TO
	Depuis	DateTime	EQUAL_TO
	Valeurs	Liste	N/A
	Title	Chaîne	N/A
	Description	Chaîne	N/A
	description_de_api_doc	Chaîne	N/A
	Id	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
Impressions de pages	Nom	Chaîne	N/A
	Période	Période	EQUAL_TO
	Depuis	DateTime	EQUAL_TO
	Valeurs	Liste	N/A
	Title	Chaîne	N/A
	Description	Chaîne	N/A
	description_de_api_doc	Chaîne	N/A
	Id	Chaîne	N/A
Publications de page	Nom	Chaîne	N/A
	Période	Période	EQUAL_TO
	Depuis	DateTime	EQUAL_TO
	Valeurs	Liste	N/A
	Title	Chaîne	N/A
	Description	Chaîne	N/A
	description_de_api_doc	Chaîne	N/A
	Id	Chaîne	N/A
Engagement lié à la publication de	Nom	Chaîne	N/A
	Période	Période	EQUAL_TO
	Valeurs	Liste	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Title	Chaîne	N/A
	Description	Chaîne	N/A
	description_de_api_doc	Chaîne	N/A
	Id	Chaîne	N/A
Réactions aux publications sur la page	Nom	Chaîne	N/A
	Période	Période	EQUAL_TO
	Valeurs	Liste	N/A
	Title	Chaîne	N/A
	Description	Chaîne	N/A
	description_de_api_doc	Chaîne	N/A
	Id	Chaîne	N/A
Démographie des utilisateurs de la page	Nom	Chaîne	N/A
	Période	Période	EQUAL_TO
	Depuis	DateTime	EQUAL_TO
	Valeurs	Liste	N/A
	Title	Chaîne	N/A
	Description	Chaîne	N/A
	description_de_api_doc	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
Pages vues de vidéos	Id	Chaîne	N/A
	Nom	Chaîne	N/A
	Période	Période	EQUAL_TO
	Depuis	DateTime	EQUAL_TO
	Valeurs	Liste	N/A
	Title	Chaîne	N/A
	Description	Chaîne	N/A
	description_de_api_doc	Chaîne	N/A
Pages vues	Id	Chaîne	N/A
	Nom	Chaîne	N/A
	Période	Période	EQUAL_TO
	Depuis	DateTime	EQUAL_TO
	Valeurs	Liste	N/A
	Title	Chaîne	N/A
	Description	Chaîne	N/A
	description_de_api_doc	Chaîne	N/A
Publications vidéo de la page	Id	Chaîne	N/A
	Nom	Chaîne	N/A
	Période	Période	EQUAL_TO

Entité	Champ	Type de données	Opérateurs pris en charge
Pages	Depuis	DateTime	EQUAL_TO
	Valeurs	Liste	N/A
	Title	Chaîne	N/A
	Description	Chaîne	N/A
	description_de_api_doc	Chaîne	N/A
	Id	Chaîne	N/A
	Nom	Chaîne	N/A
	À propos	Chaîne	N/A
	jeton d'accès	Chaîne	N/A
	campagne publicitaire	Chaîne	N/A
	Affiliation	Chaîne	N/A
	app_id	Chaîne	N/A
	artistes_we_like	Chaîne	N/A
	Tenue	Chaîne	N/A
	Récompenses	Chaîne	N/A
	intérêts du groupe	Chaîne	N/A
	membres du groupe	Chaîne	N/A
	best_page	Chaîne	N/A
	Biographie	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Anniversaire	Chaîne	N/A
	agent de réservation	Chaîne	N/A
	Construit	Chaîne	N/A
	peut s'enregistrer	Chaîne	N/A
	can_post	Chaîne	N/A
	Catégorie	Chaîne	N/A
	liste_catégories	Liste	N/A
	Enregistrements	Entier	N/A
	aperçu de l'entreprise	Chaîne	N/A
	compte_instagram_c onnecté	Chaîne	N/A
	adresse_contact	Chaîne	N/A
	country_page_likes	Entier	N/A
	Couverture	Struct	N/A
	équipe culinaire	Chaîne	N/A
	localisation_actuelle	Chaîne	N/A
	Informations sur les options de livraison et de ramassage	Liste	N/A
	Description	Chaîne	N/A
	description_html	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	offrandes_ouvertes différemment	Liste	N/A
	réalisé par	Chaîne	N/A
	Afficher_sous-texte	Chaîne	N/A
	date_de_réponse_du re_affiché	Chaîne	N/A
	E-mails	Chaîne	N/A
	Fiançailles	Chaîne	N/A
	nombre de fans	Entier	N/A
	vidéo_vedette	Chaîne	N/A
	Fonctionnalités	Chaîne	N/A
	nombre d'abonnés	Entier	N/A
	styles_alimentaires	Liste	N/A
	Fondé	Chaîne	N/A
	info_générales	Chaîne	N/A
	directeur général	Chaîne	N/A
	Genre	Chaîne	N/A
	nom_page_ de_marque global	Chaîne	N/A
	global_brand_root_id	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	a ajouté une application	Booléen	N/A
	a une expérience de transition vers une nouvelle page	Booléen	N/A
	possède un numéro_entreprise_WhatsApp	Booléen	N/A
	possède un numéro_WhatsApp	Booléen	N/A
	Ville natale	Chaîne	N/A
	Heures	Struct	N/A
	Impressum	Chaîne	N/A
	Influences	Chaîne	N/A
	compte_entreprise_instagram/entreprise	Chaîne	N/A
	est toujours ouvert	Booléen	N/A
	is_chain	Booléen	N/A
	is_community_page	Booléen	N/A
	est_éligible au contenu de marque	Booléen	N/A
	is_messenger_bot_get_started_enabled	Booléen	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	is_messenger_platform_bot	Booléen	N/A
	est possédé	Booléen	N/A
	est définitivement fermé	Booléen	N/A
	est publié	Booléen	N/A
	Nom	Chaîne	N/A
	Tâches	Liste	N/A
	n'est pas réclamé	Booléen	N/A
	is_webhooks_subscribe	Booléen	N/A
	leadgen_tos_acceptance_time	DateTime	N/A
	leadgen_tos_accepted	Booléen	N/A
	leadgen_tos_accepting_user	Chaîne	N/A
	leadgen_tos_accepting_user	Struct	N/A
	Lien	Lien	N/A
	Emplacement	Struct	N/A
	Members	Chaîne	N/A
	statut d'évaluation du vendeur	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	messenger_ads_default_icebreakers	Liste	N/A
	messenger_ads_default_page_welcome_message	Struct	N/A
	messenger_ads_default_quick_replies	Liste	N/A
	messenger_ads_quick_replies_type	Chaîne	N/A
	Mission	Chaîne	N/A
	Mpg	Chaîne	N/A
	nom_avec_descripteur_lieu	Chaîne	N/A
	Réseau	Chaîne	N/A
	new_like_count	Entier	N/A
	offre_éligible	Booléen	N/A
	notation_étoile_globale	Float	N/A
	jeton de page	Chaîne	N/A
	page_parent	Chaîne	N/A
	Stationnement	Chaîne	N/A
	options de paiement	Struct	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	information_personnelles	Chaîne	N/A
	intérêts_personnels	Chaîne	N/A
	informations sur la sécurité pharmaceutique	Chaîne	N/A
	Téléphone	Chaîne	N/A
	options de ramassage	Liste	N/A
	type_lieu	Chaîne	N/A
	plot_outline	Chaîne	N/A
	presse_contact	Chaîne	N/A
	fourchette de prix	Chaîne	N/A
	privacy_info_url	Chaîne	N/A
	produit par	Chaîne	N/A
	Produits	Chaîne	N/A
	éligible à une promotion	Booléen	N/A
	motion_inéligible_promotion_reason	Chaîne	N/A
	transport en commun	Chaîne	N/A
	notation_count	Entier	N/A
	record_label	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	date_de sortie	Chaîne	N/A
	services de restauration	Struct	N/A
	spécialités de restaurant	Struct	N/A
	Planificateur	Chaîne	N/A
	scénario_par	Chaîne	N/A
	Saison	Chaîne	N/A
	adresse_de_ligne unique	Chaîne	N/A
	En vedette	Chaîne	N/A
	information_de démarrage	Struct	N/A
	code_boutique	Chaîne	N/A
	descripteur de localisation du magasin	Chaîne	N/A
	numéro_magasin	Entier	N/A
	Studio	Chaîne	N/A
	supports_donate_button_in_live_video	Booléen	N/A
	talking_about_count	Entier	N/A
	statut_temporaire	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	nombre de messages non lus	Entier	N/A
	nombre de notifications non lues	Entier	N/A
	nombre de messages non vus	Entier	N/A
	Nom d'utilisateur	Chaîne	N/A
	état_de vérification	Chaîne	N/A
	info_voip	Struct	N/A
	Site Web	Chaîne	N/A
	Were_here_count	Entier	N/A
	Numéro_WhatsApp	Chaîne	N/A
écrit par	Chaîne	N/A	
Aliments	Id	Chaîne	N/A
	Actions	Liste	N/A
	admin_creator	Objet	N/A
	Application	Objet	N/A
	Pièces jointes	Objets	N/A
	date_date rétroactive	DateTime	N/A
	appel à l'action	Objet	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	peut répondre en privé	Booléen	N/A
	child_attachments	Liste	N/A
	Coordinates	Struct	N/A
	heure de création	DateTime	N/A
	Événement	Struct	N/A
	hauteur_étendue	Entier	N/A
	largeur_étendue	Entier	N/A
	ciblage des flux	Objet	N/A
	De	Objet	N/A
	image complète	Chaîne	N/A
	Hauteur	Entier	N/A
	Icône	Chaîne	N/A
	éligibilité à Instagram	Chaîne	N/A
	est éligible à une promotion	Booléen	N/A
	est expiré	Booléen	N/A
	est masqué	Booléen	N/A
	est créé en ligne	Booléen	N/A
	est éligible à Instagram	Booléen	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	est populaire	Booléen	N/A
	est publié	Booléen	N/A
	est sphérique	Booléen	N/A
	Message	Chaîne	N/A
	balises de message	Liste	N/A
	multi_share_end_card	Booléen	N/A
	optimisé pour plusieurs partages	Booléen	N/A
	identifiant_parent	Chaîne	N/A
	URL du permalien	Chaîne	N/A
	Lieu	Chaîne	N/A
	Confidentialité	Objet	N/A
	identifiant_promotionnel	Chaîne	N/A
	état_de la promotion	Chaîne	N/A
	Propriétés	Liste	N/A
	heure_de_publication planifiée	Float	N/A
	Partage	Objet	N/A
	type_statut	Chaîne	N/A
	Récit	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	story_tags	Liste	N/A
	Abonné	Booléen	N/A
	Cible	Struct	N/A
	Ciblage	Objet	N/A
	Pour	Objet	N/A
	visibilité chronologique	Chaîne	N/A
	heure_mise à jour	DateTime	N/A
	Via	Struct	N/A
	éligibilité à l'achat de vidéos	Liste	N/A
	Largeur	Entier	N/A
	Depuis	DateTime	EQUAL_TO

Requêtes de partitionnement

Partitionnement basé sur des filtres :

Vous pouvez fournir les options supplémentaires de Spark

PARTITION_FIELD, LOWER_BOUND, UPPER_BOUND, et NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- PARTITION_FIELD: le nom du champ à utiliser pour partitionner la requête.
- LOWER_BOUND: une valeur de limite inférieure inclusive du champ de partition choisi.

Pour le champ Datetime, nous acceptons le format d'horodatage Spark utilisé dans les requêtes SQL Spark.

Exemples de valeurs valides :

```
"2024-09-30T01:01:01.000Z"
```

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: le nombre de partitions.

Exemple :

```
facebookPageInsights_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="facebookpageinsights",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "entityName",  
        "API_VERSION": "v21",  
        "PARTITION_FIELD": "created_Time"  
        "LOWER_BOUND": "2024-10-27T07:00:00+0000"  
        "UPPER_BOUND": "2024-10-27T07:00:00+0000"  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Options de connexion à Facebook Page Insights

Les options de connexion pour Facebook Page Insights sont les suivantes :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Facebook Page Insights.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Rest de Facebook Page Insights que vous souhaitez utiliser.
- SELECTED_FIELDS(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- FILTER_PREDICATE(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- QUERY(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- PARTITION_FIELD(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.

- LOWER_BOUND(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- UPPER_BOUND(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.
- INSTANCE_URL(Chaîne) - (Obligatoire) Utilisé pour la lecture. URL d'instance Facebook Page Insights valide.

Limitations et remarques relatives au connecteur Facebook Page Insights

Voici les limites ou remarques relatives au connecteur Facebook Page Insights :

- La plupart des statistiques seront mises à jour toutes les 24 heures.
- Seules les données d'information des deux dernières années sont disponibles.
- Seuls 90 jours d'informations peuvent être consultées à la fois lorsque vous utilisez les `until` paramètres `since` et.

Connexion à Freshdesk

Freshdesk est un logiciel de support client basé sur le cloud qui est à la fois riche en fonctionnalités et facile à utiliser. Grâce aux multiples canaux d'assistance disponibles, notamment le chat en direct, le courrier électronique, le téléphone et les réseaux sociaux, vous pouvez aider les clients par le biais de leur méthode de communication préférée. Si vous êtes un utilisateur de Freshdesk, vous pouvez vous connecter AWS Glue à votre compte Freshdesk. Vous pouvez utiliser Freshdesk comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données de Freshdesk vers AWS des services ou d'autres applications prises en charge.

Rubriques

- [AWS Glue support pour Freshdesk](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Freshdesk](#)
- [Configuration des connexions Freshdesk](#)
- [Lecture à partir d'entités Freshdesk](#)
- [Options de connexion Freshdesk](#)

- [Limitations et remarques relatives au connecteur Freshdesk](#)

AWS Glue support pour Freshdesk

AWS Glue prend en charge Freshdesk comme suit :

Supportée en tant que source ?

Oui — Synchronisation et asynchronisation. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Freshdesk.

Soutenu en tant que cible ?

Non.

Versions de l'API Freshdesk prises en charge

Les versions suivantes de l'API Freshdesk sont prises en charge :

- v2

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

```
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Freshdesk

Avant de pouvoir AWS Glue transférer des données depuis Freshdesk, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Un compte Freshdesk. Vous pouvez choisir entre les éditions Free, Growth, Pro ou Enterprise.
- Clé d'API d'un utilisateur de Freshdesk.

Configuration des connexions Freshdesk

Freshdesk prend en charge l'authentification personnalisée.

Pour consulter la documentation publique de Freshdesk sur la génération des clés d'API requises pour une autorisation personnalisée, consultez la section Authentification [Freshdesk](#).

Voici les étapes à suivre pour configurer la connexion Freshdesk :

- Dans AWS Secrets Manager, créez un secret avec les informations suivantes :

- Pour une application connectée gérée par le client, le secret doit contenir la clé API de l'application connectée avec `apiKey` comme clé. Notez que vous devez créer un secret par connexion dans AWS Glue.
- Dans le AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 - Lorsque vous sélectionnez une source de données, sélectionnez Freshdesk.
 - Indiquez `INSTANCE_URL` l'instance Freshdesk à laquelle vous souhaitez vous connecter.
 - Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
- Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
- Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.
- Dans la configuration de votre AWS Glue tâche, fournissez `connectionName` une connexion réseau supplémentaire.

Lecture à partir d'entités Freshdesk

Prérequis

Un objet Freshdesk que vous souhaitez lire. Vous aurez besoin du nom de l'objet.

Entités prises en charge pour Sync source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Agents	Oui	Oui	Non	Oui	Oui
Heures d'ouverture	Non	Oui	Non	Oui	Oui
Société	Oui	Oui	Non	Oui	Oui
Contacts	Oui	Oui	Non	Oui	Oui
Conversations	Non	Oui	Non	Oui	Non
Configurations des e-mails	Non	Oui	Non	Oui	Non
Boîtes de réception de courrier électronique	Oui	Oui	Oui	Oui	Non
Catégories du forum	Non	Oui	Non	Oui	Non
Forums	Non	Oui	Non	Oui	Non
Groups	Non	Oui	Non	Oui	Non
Produits	Non	Oui	Non	Oui	Non
Rôles	Non	Oui	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Cotes de satisfaction	Oui	Oui	Non	Oui	Non
Compétences	Non	Oui	Non	Oui	Non
Solutions	Oui	Oui	Non	Oui	Non
Enquêtes	Non	Oui	Non	Oui	Non
Tickets	Oui	Oui	Oui	Oui	Oui
Entrées temporelles	Oui	Oui	Non	Oui	Non
Rubriques	Non	Oui	Non	Oui	Non
Commentaires sur le sujet	Non	Oui	Non	Oui	Non

Entités prises en charge pour la source asynchrone :

Entité	Version de l'API	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Entreprises	v2	Non	Non	Non	Non	Non
Contacts	v2	Non	Non	Non	Non	Non

Exemple :

```
freshdesk_read = glueContext.create_dynamic_frame.from_options(
    connection_type="freshdesk",
```

```
connection_options={
    "connectionName": "connectionName",
    "ENTITY_NAME": "entityName",
    "API_VERSION": "v2"
}
```

Détails de l'entité et du champ Freshdesk :

Entité	Champ
Agents	https://developers.freshdesk.com/api/#list_all_agents
Heures d'ouverture	https://developers.freshdesk.com/api/#list_all_business_hours
Commentaires	https://developers.freshdesk.com/api/#comment_attributes
Société	https://developers.freshdesk.com/api/#companies
Contacts	https://developers.freshdesk.com/api/#list_all_contacts
Conversations	https://developers.freshdesk.com/api/#list_all_ticket_notes
Configurations de courrier électronique	https://developers.freshdesk.com/api/#list_all_email_configs
Boîtes de réception électroniques	https://developers.freshdesk.com/api/#list_all_email_mailboxes
Catégories du forum	https://developers.freshdesk.com/api/#category_attributes
Forums	https://developers.freshdesk.com/api/#forum_attributes

Entité	Champ
Groups	https://developers.freshdesk.com/api/#list_all_groups
Produits	https://developers.freshdesk.com/api/#list_all_products
Rôles	https://developers.freshdesk.com/api/#list_all_roles
Cote de satisfaction	https://developers.freshdesk.com/api/#view_all_satisfaction_ratings
Compétences	https://developers.freshdesk.com/api/#list_all_skills
Solutions	https://developers.freshdesk.com/api/#solution_content
Enquêtes	https://developers.freshdesk.com/api/#list_all_survey
Tickets	https://developers.freshdesk.com/api/#list_all_tickets
Entrées temporelles	https://developers.freshdesk.com/api/#list_all_time_entries
Rubriques	https://developers.freshdesk.com/api/#topic_attributes

Requêtes de partitionnement

Partitionnement basé sur des filtres :

Vous pouvez fournir les options supplémentaires de Spark

PARTITION_FIELD_LOWER_BOUND, UPPER_BOUND, et NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en

NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- PARTITION_FIELD: le nom du champ à utiliser pour partitionner la requête.
- LOWER_BOUND: une valeur inférieure inclusive du champ de partition choisi.

Pour le champ Datetime, nous acceptons le format d'horodatage Spark utilisé dans les requêtes SQL Spark.

Exemples de valeurs valides :

```
"2024-09-30T01:01:01.000Z"
```

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: le nombre de partitions.

Exemple :

```
freshDesk_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="freshdesk",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "entityName",  
        "API_VERSION": "v2",  
        "PARTITION_FIELD": "Created_Time",  
        "LOWER_BOUND": " 2024-10-27T23:16:08Z",  
        "UPPER_BOUND": " 2024-10-27T23:16:08Z",  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Options de connexion Freshdesk

Les options de connexion pour Freshdesk sont les suivantes :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Freshdesk.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Freshdesk Rest que vous souhaitez utiliser.

- **SELECTED_FIELDS(Liste<String>)** - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE(String)** - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY(String)** - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD(String)** - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND(String)** - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND(String)** - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS(Entier)** - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.
- **INSTANCE_URL(Chaîne)** - (Obligatoire) Utilisé pour la lecture. URL d'instance Freshdesk valide.
- **TRANSFER_MODE(String)** - Utilisé pour indiquer si le type de traitement ASYNC est similaire SYNC ou défini SYNC par défaut. (Facultatif)

Limitations et remarques relatives au connecteur Freshdesk

Voici les limitations ou remarques relatives au connecteur Freshdesk :

- Les Tickets entités Company, Contacts, et avec filtrage ont des limites de pagination. Ils ne renvoient que 30 enregistrements par page et la valeur de la page peut être définie jusqu'à 10 (pour un maximum de 300 enregistrements).
- L'entité Tickets ne récupère pas les enregistrements datant de plus de 30 jours.
- Les Tickets entités Company, Contacts, et prennent en charge le type de données « Date » dans le filtrage. Vous devez sélectionner les fréquences de déclenchement « quotidiennes » et suivantes pour ces trois entités. Si vous sélectionnez « Minutes » ou « Horaire », vous risquez de dupliquer les données. De plus, lors de la sélection de ces champs pour le filtrage, seule la valeur de date doit être sélectionnée, car elle ne prendra en compte que la partie date de l'horodatage sélectionné.
- Le nombre d'appels d'API par minute dépend de votre forfait. Cette limite est appliquée à l'ensemble du compte indépendamment de facteurs tels que le nombre d'agents ou les adresses IP utilisées pour passer les appels. Pour tous les utilisateurs de la version d'essai, la limite d'API par défaut est de 50 appels/minute. Pour plus de détails, consultez [Freshdesk](#)

- Pour chaque entité, un seul Export/Async Job est traité à la fois. Une nouvelle tâche ne sera traitée que lorsque la tâche existante sera terminée avec succès ou aura échoué. Pour plus de détails, consultez [Freshdesk](#)
- Les champs suivants sont pris en charge pour les appels d'API de synchronisation, mais leur transmission dans le corps de la demande d'API asynchrone n'est pas autorisée.
 - id
 - created_at
 - updated_at
 - mis à jour depuis
 - actif
 - identifiant_entreprise
 - autres_entreprises
 - avatar
 - Afficher tous les billets
 - deleted
 - autres_e-mails
 - state
 - balise
 - balises

Connexion à Freshsales

Freshsales est un CRM intuitif qui aide les commerciaux à éliminer les incertitudes liées aux ventes. Grâce au téléphone, au courrier électronique, aux tâches, aux rendez-vous et aux notes intégrés, les commerciaux n'ont pas à passer d'un onglet à l'autre pour suivre les prospects. Vous pouvez mieux gérer vos transactions grâce à la vue du pipeline et obtenir la conclusion d'un plus grand nombre de transactions. Si vous êtes un utilisateur de Freshsales, vous pouvez vous connecter AWS Glue à votre compte Freshsales. Vous pouvez utiliser Freshsales comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer les données de Freshsales vers des AWS services ou d'autres applications prises en charge.

Rubriques

- [AWS Glue support pour Freshsales](#)

- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Freshsales](#)
- [Configuration des connexions Freshsales](#)
- [Lecture provenant des entités Freshsales](#)
- [Options de connexion Freshsales](#)
- [Limites des ventes de Fresh](#)

AWS Glue support pour Freshsales

AWS Glue soutient Freshsales comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Freshsales.

Soutenu en tant que cible ?

Non

Versions de l'API Freshsales prises en charge

Les versions suivantes de l'API Freshsales sont prises en charge :

- v1.0

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
```

```
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
    ],
    "Resource": "*"
}
]
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Freshsales

Avant de pouvoir AWS Glue transférer des données depuis Freshsales, vous devez répondre aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un compte Freshsales.
- Vous disposez d'une clé d'API utilisateur.

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Freshsales. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Freshsales.

Configuration des connexions Freshsales

Freshsales prend en charge l'authentification personnalisée.

Pour consulter la documentation publique de Freshsales sur la génération des clés d'API requises pour une authentification personnalisée, consultez [Authentification](#).

Pour configurer une connexion Freshsales :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir la clé API de l'application connectée avec *apiSecretKey* comme clé. Le secret doit également contenir une autre paire clé-valeur avec *apiKey* comme clé et *token* comme valeur.
 - b. Remarque : vous devez créer un secret pour vos connexions dans AWS Glue.
1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez une source de données, sélectionnez Freshsales.
 - b. Indiquez le INSTANCE_URL compte Freshsales auquel vous souhaitez vous connecter.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture provenant des entités Freshsales

Prérequis

Un objet Freshsales dont vous aimeriez lire un extrait. Vous aurez besoin du nom de l'objet.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Comptes	Oui	Oui	Oui	Oui	Oui
Contacts	Oui	Oui	Oui	Oui	Oui

Exemple :

```
freshSales_read = glueContext.create_dynamic_frame.from_options(
    connection_type="freshsales",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v1.0"
    }
)
```

Détails de l'entité et du champ Freshsales :

Freshsales fournit des points de terminaison permettant de récupérer les métadonnées de manière dynamique pour les entités prises en charge. Par conséquent, le support de l'opérateur est capturé au niveau du type de données.

Entité	Type de données	Opérateurs pris en charge
Entités Freshsale (toutes)	Entier	! =, =, <, <=, >, >=, ENTRE
	Chaîne	Comme, =, !=
	BigInteger	! =, =, <, <=, >, >=, ENTRE
	Booléen	=
	Double	! =, =, <, <=, >, >=, ENTRE
	BigDecimal	! =, =, <, <=, >, >=, ENTRE
	Date	! =, =, <, <=, >, >=, ENTRE
	DateTime	! =, =, <, <=, >, >=, ENTRE
	Struct	N/A
	Liste	N/A

Requêtes de partitionnement

Partitionnement basé sur des filtres :

Vous pouvez fournir les options supplémentaires de Spark

PARTITION_FIELD, LOWER_BOUND, UPPER_BOUND, et NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- PARTITION_FIELD: le nom du champ à utiliser pour partitionner la requête.
- LOWER_BOUND: une valeur inférieure inclusive du champ de partition choisi.

Pour le champ Datetime, nous acceptons la valeur au format ISO.

Exemples de valeurs valides :

```
"2024-09-30T01:01:01.000Z"
```

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: le nombre de partitions.

Exemple :

```
freshSales_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="freshsales",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "entityName",  
        "API_VERSION": "v1",  
        "PARTITION_FIELD": "Created_Time"  
        "LOWER_BOUND": " 2024-10-15T21:16:25Z"  
        "UPPER_BOUND": " 2024-10-20T21:25:50Z"  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Options de connexion Freshsales

Les options de connexion pour Freshsales sont les suivantes :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Freshsales.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Rest de Freshsales que vous souhaitez utiliser.
- SELECTED_FIELDS(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- FILTER_PREDICATE(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- QUERY(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- PARTITION_FIELD(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- LOWER_BOUND(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- UPPER_BOUND(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

- `INSTANCE_URL(String)` - Utilisé pour la lecture. URL d'instance Freshsales valide.

Limites des ventes de Fresh

Voici les limites ou remarques relatives à Freshsales :

- Dans Freshsales, la limite de débit d'API est de 1 000 demandes d'API par heure et par compte (voir [Erreurs](#)). Mais cette limite est extensible avec le plan d'abonnement Enterprise (voir le [comparatif des forfaits](#)).

Connexion à Google Ads

L'API Google Ads est l'interface programmatique de Google Ads, utilisée pour gérer des comptes et des campagnes Google Ads volumineux ou complexes. Si vous utilisez Google Ads, vous pouvez vous connecter AWS Glue à votre compte Google Ads. Vous pouvez ensuite utiliser Google Ads comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre Google Ads et AWS les services ou autres applications compatibles.

Rubriques

- [AWS Glue support pour Google Ads](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Google Ads](#)
- [Configuration des connexions Google Ads](#)
- [Lecture à partir d'entités Google Ads](#)
- [Options de connexion à Google Ads](#)
- [Création d'un compte Google Ads](#)
- [Limites](#)

AWS Glue support pour Google Ads

AWS Glue prend en charge Google Ads comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Google Ads.

Soutenu en tant que cible ?

Non.

Versions de l'API Google Ads prises en charge

v18

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Vous pouvez également utiliser les politiques IAM gérées suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Google Ads

Avant de pouvoir AWS Glue effectuer un transfert depuis Google Ads, vous devez remplir les conditions suivantes :

Configuration requise

- Vous possédez un compte Google Ads avec adresse e-mail et mot de passe. Pour plus d'informations sur la création d'un compte, consultez la section [Création d'un compte Google Ads](#).
- Votre compte Google Ads est activé pour accéder à l'API. Toute utilisation de l'API Google Ads est disponible sans frais supplémentaires.
- Votre compte Google Ads vous permet d'installer des applications connectées. Si vous n'avez pas accès à cette fonctionnalité, contactez votre administrateur Google Ads.

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Google Ads.

Configuration des connexions Google Ads

Google Ads prend en charge les types de `AUTHORIZATION_CODE` subventions pour OAuth2.

Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. La AWS Glue console redirige l'utilisateur vers Google Ads où il doit se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Google Ads.

Les utilisateurs peuvent choisir de créer leur propre application connectée dans Google Ads et de fournir leur propre identifiant client et leur secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Google Ads pour se connecter et autoriser AWS Glue l'accès à leurs ressources.

Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.

Pour plus d'informations, consultez la [documentation publique de Google Ads sur la création d'une application connectée pour le OAuth flux de code d'autorisation](#).

Pour configurer une connexion Google Ads, procédez comme suit :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes. Il est nécessaire de créer un secret pour chaque connexion dans AWS Glue.
 - a. Pour le type de AuthorizationCode subvention :
 - Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET comme clé.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Google Ads.
 - b. Indiquez developer_token les annonces Google auxquelles vous souhaitez vous connecter.
 - c. Indiquez le MANAGER ID nom de Google Ads si vous souhaitez vous connecter en tant que responsable.
 - d. Sélectionnez le rôle IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- e. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - f. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture à partir d'entités Google Ads

Prérequis

- Un objet Google Ads dont vous souhaitez lire un extrait. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Annonce de groupe d'annonces	Oui	Oui	Oui	Non	Oui
Groupe d'annonces	Oui	Oui	Oui	Non	Oui
Budget de campagne	Oui	Oui	Oui	Oui	Oui
Budget du compte	Oui	Non	Oui	Oui	Non
Campagne	Oui	Oui	Oui	Oui	Oui
Compte	Oui	Non	Oui	Non	Non

Exemple

```
googleAds_read = glueContext.create_dynamic_frame.from_options(
    connection_type="googleads",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "campaign-3467***",
        "API_VERSION": "v16"
    }
)
```

Informations sur l'entité et le champ Google Ads

Entité	Champ	Type de données	Opérateurs pris en charge
Compte	resourceName	Chaîne	!=, =
Compte	callReportingEnabled	Booléen	!=, =
Compte	callConversionReportingActivé	Booléen	!=, =
Compte	callConversionAction	Chaîne	!=, =
Compte	conversionTrackingId	BigInteger	ENTRE, =, !=, <, >, <=, >=
Compte	crossAccountConversionTrackingId	BigInteger	ENTRE, =, !=, <, >, <=, >=
Compte	payPerConversionEligibilityFailureReasons	Liste	
Compte	id	BigInteger	ENTRE, =, !=, <, >, <=, >=
Compte	currencyCode	Chaîne	!=, =, COMME
Compte	Fuseau horaire	Chaîne	!=, =, COMME
Compte	autoTaggingEnabled	Booléen	!=, =
Compte	hasPartnersBadge	Booléen	!=, =
Compte	manager	Booléen	!=, =
Compte	Compte de test	Booléen	!=, =
Compte	date	Date	ENTRE, =, <, >, <=, >=

Entité	Champ	Type de données	Opérateurs pris en charge
Compte	CostMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Compte	acceptedCustomerDataTerms	Booléen	
Compte	conversionTrackingStatus	Chaîne	!=, =, COMME
Compte	enhancedConversionsForLeadsEnabled	Booléen	
Compte	googleAdsConversionClient	Chaîne	
Compte	status	Chaîne	!=, =
Compte	allConversionsByConversionDate	Double	!=, =, <, >
Compte	allConversionsValueByConversionDate	Double	!=, =, <, >
Compte	conversionsByConversionDate	Double	!=, =, <, >
Compte	conversionsValueByConversionDate	Double	!=, =, <, >
Compte	valuePerAllConversionsByConversionDate	Double	!=, =, <, >
Compte	Vues vidéo	BigInteger	ENTRE, =, !=, <, >, <=, >=

Entité	Champ	Type de données	Opérateurs pris en charge
Compte	clics	BigInteger	ENTRE, =, !=, <, >, <=, >=
Compte	Clics non valides	BigInteger	ENTRE, =, !=, <, >, <=, >=
Compte	costPerAllConversions	Double	!=, =, <, >
Compte	costPerConversion	Double	!=, =, <, >
Compte	conversions	Double	!=, =, <, >
Compte	absoluteTopImpressionPourcentage	Double	!=, =, <, >
Compte	impressions	BigInteger	ENTRE, =, !=, <, >, <=, >=
Compte	topImpressionPercentage	Double	!=, =, <, >
Compte	CPC moyen	Double	!=, =, <, >
Compte	activeViewMeasurableCostMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Compte	Coût moyen	Double	!=, =, <, >
Compte	ctr	Double	!=, =, <, >
Compte	activeViewCtr	Double	!=, =, <, >
Compte	searchImpressionShare	Double	!=, =, <, >
Compte	Action de conversion	Chaîne	!=, =

Entité	Champ	Type de données	Opérateurs pris en charge
Compte	conversionActionCategory	Chaîne	!=, =
Compte	conversionActionName	Chaîne	!=, =, COMME
Budget du compte	resourceName	Chaîne	!=, =
Budget du compte	status	Chaîne	!=, =
Budget du compte	proposedEndTimeType	Chaîne	!=, =
Budget du compte	approvedEndTimeType	Chaîne	!=, =
Budget du compte	id	BigInteger	ENTRE, =, !=, <, >, <=, >=
Budget du compte	Configuration de la facturation	Chaîne	!=, =
Budget du compte	name	Chaîne	!=, =, COMME
Budget du compte	approvedStartDateHeure	DateTime	ENTRE, =, <, >, <=, >=
Budget du compte	proposedSpendingLimitMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Budget du compte	approvedSpendingLimitMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Budget du compte	adjustedSpendingLimitMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=

Entité	Champ	Type de données	Opérateurs pris en charge
Budget du compte	amountServedMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	resourceName	Chaîne	!=, =, COMME
Groupe d'annonces	status	Chaîne	!=, =, COMME
Groupe d'annonces	type	Chaîne	!=, =, COMME
Groupe d'annonces	id	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	name	Chaîne	!=, =, COMME
Groupe d'annonces	campaign	Chaîne	!=, =
Groupe d'annonces	cpcBidMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	targetCpaMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	cpmBidMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	cpvBidMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	targetCpmMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	effectiveTargetCpaMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	date	Date	ENTRE, =, <, >, <=, >=

Entité	Champ	Type de données	Opérateurs pris en charge
Groupe d'annonces	CostMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	useAudienceGrouped	Booléen	!=, =
Groupe d'annonces	effectiveCpcBidMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	allConversionsByConversionDate	Double	!=, =, <, >
Groupe d'annonces	allConversionsValueByConversionDate	Double	!=, =, <, >
Groupe d'annonces	conversionsByConversionDate	Double	!=, =, <, >
Groupe d'annonces	conversionsValueByConversionDate	Double	!=, =, <, >
Groupe d'annonces	valuePerAllConversionsByConversionDate	Double	!=, =, <, >
Groupe d'annonces	valuePerConversionsByConversionDate	Double	!=, =, <, >
Groupe d'annonces	Coût moyen	Double	!=, =, <, >
Groupe d'annonces	costPerAllConversions	Double	!=, =, <, >
Groupe d'annonces	costPerConversion	Double	!=, =, <, >
Groupe d'annonces	averagePageViews	Double	!=, =, <, >

Entité	Champ	Type de données	Opérateurs pris en charge
Groupe d'annonces	Vues vidéo	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	clics	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	Toutes les conversions	Double	!=, =, <, >
Groupe d'annonces	CPC moyen	Double	!=, =, <, >
Groupe d'annonces	absoluteTopImpressionPourcentage	Double	!=, =, <, >
Groupe d'annonces	impressions	BigInteger	ENTRE, =, !=, <, >, <=, >=
Groupe d'annonces	topImpressionPercentage	Double	!=, =, <, >
Groupe d'annonces	activeViewCtr	Double	!=, =, <, >
Groupe d'annonces	ctr	Double	!=, =, <, >
Groupe d'annonces	searchTopImpressionPartagez	Double	!=, =, <, >
Groupe d'annonces	searchImpressionShare	Double	!=, =, <, >
Groupe d'annonces	searchAbsoluteTopImpressionShare	Double	!=, =, <, >
Groupe d'annonces	CTR relatif	Double	!=, =, <, >
Groupe d'annonces	Action de conversion	Chaîne	!=, =

Entité	Champ	Type de données	Opérateurs pris en charge
Groupe d'annonces	conversionActionCategory	Chaîne	!=, =
Groupe d'annonces	conversionActionName	Chaîne	!=, =, COMME
Groupe d'annonces	Mettre à jour le masque	Chaîne	
Groupe d'annonces	créer	Struct	
Groupe d'annonces	mise à jour	Struct	
Groupe d'annonces	État principal	Chaîne	!=, =
Groupe d'annonces	primaryStatusReasons	Liste	
Annonce de groupe d'annonces	resourceName	Chaîne	!=, =
Annonce de groupe d'annonces	id	BigInteger	ENTRE, =, !=, <, >, <=, >=
Annonce de groupe d'annonces	status	Chaîne	!=, =
Annonce de groupe d'annonces	labels	Liste	
Annonce de groupe d'annonces	Groupe d'annonces	Chaîne	!=, =
Annonce de groupe d'annonces	CostMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=

Entité	Champ	Type de données	Opérateurs pris en charge
Annonce de groupe d'annonces	État d'approbation	Chaîne	!=, =
Annonce de groupe d'annonces	État de la révision	Chaîne	!=, =
Annonce de groupe d'annonces	Force de la publicité	Chaîne	!=, =
Annonce de groupe d'annonces	type	Chaîne	!=, =
Annonce de groupe d'annonces	Nom de l'entreprise	Chaîne	!=, =, COMME
Annonce de groupe d'annonces	date	Date	ENTRE, =, <, >, <=, >=
Annonce de groupe d'annonces	allConversionsByConversionDate	Double	!=, =, <, >
Annonce de groupe d'annonces	allConversionsValueByConversionDate	Double	!=, =, <, >
Annonce de groupe d'annonces	conversionsByConversionDate	Double	!=, =, <, >
Annonce de groupe d'annonces	conversionsValueByConversionDate	Double	!=, =, <, >
Annonce de groupe d'annonces	valuePerAllConversionsByConversionDate	Double	!=, =, <, >
Annonce de groupe d'annonces	valuePerConversionsByConversionDate	Double	!=, =, <, >

Entité	Champ	Type de données	Opérateurs pris en charge
Annonce de groupe d'annonces	activeViewMeasurableCostMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Annonce de groupe d'annonces	Coût moyen	Double	!=, =, <, >
Annonce de groupe d'annonces	costPerAllConversions	Double	!=, =, <, >
Annonce de groupe d'annonces	costPerConversion	Double	!=, =, <, >
Annonce de groupe d'annonces	clics	BigInteger	ENTRE, =, !=, <, >, <=, >=
Annonce de groupe d'annonces	averagePageViews	Double	!=, =, <, >
Annonce de groupe d'annonces	Vues vidéo	BigInteger	ENTRE, =, !=, <, >, <=, >=
Annonce de groupe d'annonces	Toutes les conversions	Double	!=, =, <, >
Annonce de groupe d'annonces	CPC moyen	Double	!=, =, <, >
Annonce de groupe d'annonces	topImpressionPercentage	Double	!=, =, <, >
Annonce de groupe d'annonces	impressions	BigInteger	ENTRE, =, !=, <, >, <=, >=
Annonce de groupe d'annonces	absoluteTopImpressionPercentage	Double	!=, =, <, >

Entité	Champ	Type de données	Opérateurs pris en charge
Annonce de groupe d'annonces	activeViewCtr	Double	!=, =, <, >
Annonce de groupe d'annonces	ctr	Double	!=, =, <, >
Annonce de groupe d'annonces	Action de conversion	Chaîne	!=, =
Annonce de groupe d'annonces	conversionActionCategory	Chaîne	!=, =
Annonce de groupe d'annonces	conversionActionName	Chaîne	!=, =, COMME
Annonce de groupe d'annonces	Mettre à jour le masque	Chaîne	
Annonce de groupe d'annonces	créer	Struct	
Annonce de groupe d'annonces	mise à jour	Struct	
Annonce de groupe d'annonces	policyValidationParameter	Struct	
Annonce de groupe d'annonces	État principal	Chaîne	!=, =
Annonce de groupe d'annonces	primaryStatusReasons	Liste	
Campagne	resourceName	Chaîne	!=, =
Campagne	status	Chaîne	!=, =

Entité	Champ	Type de données	Opérateurs pris en charge
Campagne	Campagne de base	Chaîne	!=, =
Campagne	name	Chaîne	!=, =, COMME
Campagne	id	BigInteger	ENTRE, =, !=, <, >, <=, >=
Campagne	Budget de campagne	Chaîne	!=, =, COMME
Campagne	startDate	Date	ENTRE, =, <, >, <=, >=
Campagne	endDate	Date	ENTRE, =, <, >, <=, >=
Campagne	adServingOptimizationÉtat	Chaîne	!=, =
Campagne	advertisingChannelType	Chaîne	!=, =
Campagne	advertisingChannelSubType	Chaîne	!=, =
Campagne	Type d'expérience	Chaîne	!=, =
Campagne	État de la portion	Chaîne	!=, =
Campagne	biddingStrategyType	Chaîne	!=, =
Campagne	domainName	Chaîne	!=, =, COMME
Campagne	languageCode	Chaîne	!=, =, COMME
Campagne	useSuppliedUrlsSeulement	Booléen	!=, =

Entité	Champ	Type de données	Opérateurs pris en charge
Campagne	positiveGeoTargetType	Chaîne	!=, =
Campagne	negativeGeoTargetType	Chaîne	!=, =
Campagne	Mode de paiement	Chaîne	!=, =
Campagne	optimizationGoalTypes	Liste	
Campagne	date	Date	ENTRE, =, <, >, <=, >=
Campagne	Coût moyen	Double	
Campagne	clics	BigInteger	ENTRE, =, !=, <, >, <=, >=
Campagne	CostMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Campagne	impressions	BigInteger	ENTRE, =, !=, <, >, <=, >=
Campagne	useAudienceGrouped	Booléen	!=, =
Campagne	activeViewMeasurableCostMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Campagne	costPerAllConversions	Double	!=, =, <, >
Campagne	costPerConversion	Double	!=, =, <, >
Campagne	Clics non valides	BigInteger	ENTRE, =, !=, <, >, <=, >=

Entité	Champ	Type de données	Opérateurs pris en charge
Campagne	publisherPurchased Clicks	BigInteger	ENTRE, =, !=, <, >, <=, >=
Campagne	averagePageViews	Double	!=, =, <, >
Campagne	Vues vidéo	BigInteger	ENTRE, =, !=, <, >, <=, >=
Campagne	allConversionsByConversionDate	Double	!=, =, <, >
Campagne	allConversionsValueByConversionDate	Double	!=, =, <, >
Campagne	conversionsByConversionDate	Double	!=, =, <, >
Campagne	conversionsValueByConversionDate	Double	!=, =, <, >
Campagne	valuePerAllConversionsByConversionDate	Double	!=, =, <, >
Campagne	valuePerConversionsByConversionDate	Double	!=, =, <, >
Campagne	Toutes les conversions	Double	!=, =, <, >
Campagne	absoluteTopImpressionPourcentage	Double	!=, =, <, >
Campagne	searchAbsoluteTopImpressionShare	Double	!=, =, <, >
Campagne	CPC moyen	Double	!=, =, <, >

Entité	Champ	Type de données	Opérateurs pris en charge
Campagne	searchImpressionShare	Double	!=, =, <, >
Campagne	searchTopImpressionPartagez	Double	!=, =, <, >
Campagne	activeViewCtr	Double	!=, =, <, >
Campagne	ctr	Double	!=, =, <, >
Campagne	CTR relatif	Double	!=, =, <, >
Campagne	Mettre à jour le masque	Chaîne	
Campagne	créer	Struct	
Campagne	mise à jour	Struct	
Budget de campagne	resourceName	Chaîne	!=, =
Budget de campagne	id	BigInteger	ENTRE, =, !=, <, >, <=, >=
Budget de campagne	status	Chaîne	!=, =
Budget de campagne	Mode de livraison	Chaîne	!=, =
Budget de campagne	point	Chaîne	!=, =
Budget de campagne	type	Chaîne	!=, =
Budget de campagne	name	Chaîne	!=, =, COMME
Budget de campagne	Quantité de micros	BigInteger	ENTRE, =, !=, <, >, <=, >=

Entité	Champ	Type de données	Opérateurs pris en charge
Budget de campagne	Partagé de manière explicite	Booléen	!=, =
Budget de campagne	Nombre de références	BigInteger	ENTRE, =, !=, <, >, <=, >=
Budget de campagne	hasRecommendedBudget	Booléen	!=, =
Budget de campagne	date	Date	ENTRE, =, <, >, <=, >=
Budget de campagne	CostMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Budget de campagne	startDate	Date	ENTRE, =, <, >, <=, >=
Budget de campagne	endDate	Date	ENTRE, =, <, >, <=, >=
Budget de campagne	maximizeConversionValueTargetRoas	Double	!=, =, <, >
Budget de campagne	maximizeConversionTargetCpaMicros	BigInteger	ENTRE, =, !=, <, >, <=, >=
Budget de campagne	selectiveOptimizationConversionActions	Chaîne	
Budget de campagne	Coût moyen	Double	!=, =, <, >
Budget de campagne	costPerAllConversions	Double	!=, =, <, >
Budget de campagne	costPerConversion	Double	!=, =, <, >

Entité	Champ	Type de données	Opérateurs pris en charge
Budget de campagne	Vues vidéo	BigInteger	ENTRE, =, !=, <, >, <=, >=
Budget de campagne	clics	BigInteger	ENTRE, =, !=, <, >, <=, >=
Budget de campagne	Toutes les conversions	Double	!=, =, <, >
Budget de campagne	valuePerAllConversions	Double	!=, =, <, >
Budget de campagne	CPC moyen	Double	!=, =, <, >
Budget de campagne	impressions	BigInteger	ENTRE, =, !=, <, >, <=, >=
Budget de campagne	ctr	Double	!=, =, <, >
Budget de campagne	Mettre à jour le masque	Chaîne	
Budget de campagne	créer	Struct	
Budget de campagne	mise à jour	Struct	

Requêtes de partitionnement

Des options Spark supplémentaires `PARTITION_FIELD_LOWER_BOUND`, `UPPER_BOUND`, `NUM_PARTITIONS` peuvent être fournies si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur limite inférieure inclusive du champ de partition choisi.

Pour la date, nous acceptons le format de date Spark utilisé dans les requêtes SQL Spark.

Exemple de valeurs valides : "2024-02-06".

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: nombre de partitions.

Les détails relatifs à la prise en charge des champs de partitionnement par entité sont présentés dans le tableau suivant.

Nom de l'entité	Champ de partitionnement	Type de données
Announcement	date	Date
Groupe d'annonces	date	Date
Campagne	date	Date
Budget de campagne	date	Date

Exemple

```
googleads_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="googleads",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "campaign-3467***",  
        "API_VERSION": "v16",  
        "PARTITION_FIELD": "date"  
        "LOWER_BOUND": "2024-01-01"  
        "UPPER_BOUND": "2024-06-05"  
        "NUM_PARTITIONS": "10"  
    }  
)
```


Options de connexion à Google Ads

Les options de connexion à Google Ads sont les suivantes :


- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Google Ads.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Google Ads Rest que vous souhaitez utiliser. Exemple : v16.
- **DEVELOPER_TOKEN**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Nécessaire pour authentifier le développeur ou l'application qui envoie des demandes à l'API.
- **MANAGER_ID**(String) - Utilisé pour la lecture/écriture. Identifiant unique qui vous permet de gérer plusieurs comptes Google Ads. Il s'agit de l'identifiant client du responsable autorisé. Si vous accédez au compte client par le biais d'un compte administrateur, celui-ci **MANAGER_ID** est obligatoire. Pour de plus amples informations, veuillez consulter [login-customer-id](#).
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Création d'un compte Google Ads

1. Connectez-vous au [compte de développeur Google Ads](#) à l'aide de vos informations d'identification, puis accédez à *MyProject.



2. Choisissez Nouveau projet et fournissez les informations requises pour créer un projet Google si aucune application n'y est enregistrée.



New Project

 You have 3 projects remaining in your quota. Request an increase or delete projects. [Learn more](#)

[MANAGE QUOTAS](#)

Project name *

My Project 80554 ?

Project ID: wise-perception-358309. It cannot be changed later. [EDIT](#)


Location *

 No organisation [BROWSE](#)


Parent organisation or folder

CREATE
CANCEL


3. Choisissez l'onglet Navigation, puis API et paramètres, et Créer un identifiant client, ClientSecret qui nécessitera une configuration supplémentaire pour créer une connexion entre AWS Glue et GoogleAds. Pour plus d'informations, consultez la section [Informations d'identification de l'API](#).




4. Choisissez CREATE CREDENTIALS et choisissez l'ID OAuth client.




5. Sélectionnez le type d'application en tant qu'application Web.




6. Sous Redirection autorisée URIs, ajoutez la OAuth redirection URIs et choisissez Créer. Vous pouvez ajouter plusieurs redirections URIs si nécessaire.



7. Votre identifiant client et votre secret client seront générés lors de la création d'une connexion entre AWS Glue et Google Ads.



8. Ajoutez les portées en fonction des besoins de votre application, choisissez l'écran de OAuth consentement, fournissez les informations requises et ajoutez les portées en fonction des exigences.



Limites

Les limites du connecteur Google Ads sont les suivantes :

- MANAGER_IDest une entrée facultative lors de la création d'une connexion. Mais lorsque vous souhaitez accéder aux clients sous-jacents à un gestionnaire en particulier, cette saisie MANAGER_ID est obligatoire. Le tableau ci-dessous explique les limites d'accès selon qu'il MANAGER_ID est inclus ou non dans une connexion.

MANAGER_ID fourni lors de la création de la connexion ?	Clients accessibles
Oui	Les clients répertoriés sous le MANAGER_ID fourni avec le MANAGER_ID.
Non	Tous les clients seront listés, mais les clients sous-jacents à un gestionnaire ne seront pas accessibles.

- Lorsqu'un compte administrateur est choisi comme objet, seul un sous-objet Account apparaît. Dans le connecteur Google Ads, les entités telles que les campagnes, les publicités, etc., sont extraites en fonction des comptes clients individuels, et non du compte administrateur.

- Vous ne pouvez pas récupérer les statistiques du compte administrateur. Vous pouvez plutôt récupérer des métriques pour des comptes clients individuels.
- Chaque compte peut contenir jusqu'à 10 000 campagnes, y compris des campagnes actives et en pause. Pour plus d'informations, consultez [la section Campagne par compte](#).
- Lorsque vous créez un rapport, si vous choisissez d'afficher certaines mesures, les lignes dont les mesures sélectionnées sont toutes nulles ne seront pas renvoyées. Pour plus d'informations, consultez [Zero Metrics](#).
- Avec les champs suivants, le flux de mappage complet ne fonctionnera pas pour les entités Account, Ad Group et Ad Group Ad Group Ad, en particulier pour ConversionAction,, conversionActionCategory. conversionActionName Pour plus d'informations, consultez [Segment et métriques](#).
- Un filtre de plage de dates est obligatoire lorsque le segments . date champ est sélectionné.

Connexion à Google Analytics 4

Google Analytics 4 est un service d'analyse qui suit et rapporte des statistiques concernant les interactions des visiteurs avec vos applications et sites Web. Ces statistiques incluent les pages vues, les utilisateurs actifs et les événements. Si vous êtes un utilisateur de Google Analytics 4, vous pouvez vous connecter AWS Glue à votre compte Google Analytics 4. Vous pouvez utiliser Google Analytics 4 comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données de Google Analytics 4 vers AWS des services ou d'autres applications compatibles.

Rubriques

- [AWS Glue support pour Google Analytics 4](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Google Analytics 4](#)
- [Configuration des connexions à Google Analytics 4](#)
- [Lecture depuis Google Analytics \(4 entités\)](#)
- [Options de connexion à Google Analytics 4](#)
- [Création d'un compte Google Analytics 4](#)
- [Étapes pour créer une application cliente et des informations d'identification OAuth 2.0](#)
- [Limites et considérations](#)

AWS Glue support pour Google Analytics 4

AWS Glue prend en charge Google Analytics 4 comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Google Analytics 4.

Soutenu en tant que cible ?

Non.

Versions d'API Google Analytics 4 prises en charge

v1 Bêta.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Vous pouvez également utiliser les politiques IAM gérées suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM,

CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Google Analytics 4

Avant de pouvoir AWS Glue effectuer un transfert depuis Google Analytics 4, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous possédez un compte Google Analytics avec un ou plusieurs flux de données qui collectent les données que vous souhaitez transférer.
- Vous disposez d'un compte Google Cloud Platform et d'un projet Google Cloud.
- Dans votre projet Google Cloud, vous avez activé les éléments suivants APIs :
 - API Google Analytics
 - API d'administration de Google Analytics
 - API de données Google Analytics
- Dans votre projet Google Cloud, vous avez configuré un écran de OAuth consentement pour les utilisateurs externes. Pour plus d'informations sur l'écran de OAuth consentement, consultez la section [Configuration de votre écran de OAuth consentement](#) dans l'aide de la console Google Cloud Platform.
- Dans votre projet Google Cloud, vous avez configuré un identifiant client OAuth 2.0. Pour plus d'informations, voir [Configuration de la OAuth version 2.0](#).

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Google Analytics 4.

Configuration des connexions à Google Analytics 4

Pour configurer une connexion à Google Sheet, procédez comme suit :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes. Il est nécessaire de créer un secret pour chaque connexion dans AWS Glue.
 - a. Pour le type de AuthorizationCode subvention :
 - Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET comme clé.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Google Analytics 4.
 - b. Indiquez INSTANCE_URL le Google Analytics 4 auquel vous souhaitez vous connecter.
 - c. Sélectionnez le rôle IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

AUTHORIZATION_CODEtype de subvention.

Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. La AWS Glue console redirigera l'utilisateur vers Google Analytics 4 où il devra se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Google Analytics 4.

Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans Google Analytics 4 et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Google Analytics 4 pour se connecter et autoriser AWS Glue l'accès à leurs ressources.

Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.

Pour plus d'informations, consultez la section [Utilisation de l'authentification 2.0 pour accéder à Google APIs](#).

Lecture depuis Google Analytics (4 entités)

Prérequis

- Un objet Google Analytics 4 dont vous souhaitez lire un extrait. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Rapport en temps réel	Oui	Oui	Oui	Oui	Non
Rapport de base	Oui	Oui	Oui	Oui	Oui

Exemple

```
googleAnalytics4_read = glueContext.create_dynamic_frame.from_options(
    connection_type="GoogleAnalytics4",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v1beta"
    }
)
```

Détails des entités et des champs de Google Analytics 4

Entité	Champ	Type de données	Opérateurs pris en charge
Rapport de base	Champs dynamiques		
Rapport de base	Champs de dimension	Chaîne	COMME, =
Rapport de base	Champs de dimension	Date	COMME, =
Rapport de base	Champs métriques	Chaîne	>, <, >=, <=, = ENTRE
Rapport de base	Dimension personnalisée et champs métriques personnalisés	Chaîne	NA
Rapport en temps réel	Version de l'application	Chaîne	COMME, =
Rapport en temps réel	Identifiant du public	Chaîne	COMME, =
Rapport en temps réel	Nom du public	Chaîne	COMME, =
Rapport en temps réel	city	Chaîne	COMME, =
Rapport en temps réel	ID de ville	Chaîne	COMME, =
Rapport en temps réel	country	Chaîne	COMME, =

Entité	Champ	Type de données	Opérateurs pris en charge
Rapport en temps réel	ID du pays	Chaîne	COMME, =
Rapport en temps réel	Catégorie d'appareil	Chaîne	COMME, =
Rapport en temps réel	eventName	Chaîne	COMME, =
Rapport en temps réel	Il y a quelques minutes	Chaîne	COMME, =
Rapport en temps réel	platform	Chaîne	COMME, =
Rapport en temps réel	streamId	Chaîne	COMME, =
Rapport en temps réel	streamName	Chaîne	COMME, =
Rapport en temps réel	unifiedScreenName	Chaîne	COMME, =
Rapport en temps réel	Utilisateurs actifs	Chaîne	>, <, >=, <=, = ENTRE
Rapport en temps réel	conversions	Chaîne	>, <, >=, <=, = ENTRE
Rapport en temps réel	Nombre d'événements	Chaîne	>, <, >=, <=, = ENTRE
Rapport en temps réel	screenPageViews	Chaîne	>, <, >=, <=, = ENTRE

Requêtes de partitionnement

1. Partition basée sur un filtre

Des options Spark supplémentaires `PARTITION_FIELDLOWER_BOUND`, `UPPER_BOUND`, `NUM_PARTITIONS` peuvent être fournies si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- **PARTITION_FIELD**: le nom du champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**: une valeur limite inférieure inclusive du champ de partition choisi.

Pour la date, nous acceptons le format de date Spark utilisé dans les requêtes SQL Spark.
Exemple de valeurs valides : "2024-02-06"

- **UPPER_BOUND**: une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**: nombre de partitions.

Exemple

```
googleAnalytics4_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="GoogleAnalytics4",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "entityName",  
        "API_VERSION": "v1beta",  
        "PARTITION_FIELD": "date"  
        "LOWER_BOUND": "2022-01-01"  
        "UPPER_BOUND": "2024-01-02"  
        "NUM_PARTITIONS": "10"  
    }  
)
```

2. Partition basée sur des enregistrements

Des options Spark supplémentaires **NUM_PARTITIONS** peuvent être fournies si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en **NUM_PARTITIONS** plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- **NUM_PARTITIONS**: nombre de partitions.

Exemple

```
googleAnalytics4_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="GoogleAnalytics4",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "entityName",  
        "API_VERSION": "v1beta",  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Options de connexion à Google Analytics 4

Les options de connexion pour Google Analytics 4 sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Google Analytics 4.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Rest de Google Analytics 4 que vous souhaitez utiliser.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.
- **INSTANCE_URL**(Entier) - Utilisé pour la lecture. (Facultatif)

Création d'un compte Google Analytics 4

Suivez les étapes pour créer un compte Google Analytics 4 : [https://support.google.com/analytics/answer/9304153 ? hl=fr](https://support.google.com/analytics/answer/9304153?hl=fr)

Étapes pour créer une application cliente et des informations d'identification OAuth 2.0

Pour plus d'informations, consultez la documentation de l'[API Google Analytics4](#).

1. Créez et configurez votre compte en vous connectant à votre [compte Google Analytics](#) avec vos informations d'identification. Accédez ensuite à Admin > Créer un compte.
2. Créez une propriété pour le compte que vous avez créé en choisissant Créer une propriété. Configurez la propriété avec les informations requises. Une fois tous les détails fournis, l'identifiant de propriété correspondant sera généré.

3. Ajoutez un flux de données pour la propriété créée en choisissant Flux de données > Ajouter un flux > Web dans le menu déroulant. Fournissez les détails du site Web tels que l'URL et les autres champs obligatoires. Après avoir fourni tous les détails, l'identifiant de flux et l'identifiant de mesure correspondants seront générés.
4. Configurez Google Analytics sur votre site Web en copiant l'identifiant de mesure et en l'ajoutant à la configuration de votre site Web.
5. Créez un rapport à partir de Google Analytics en accédant à Rapports et en générant le rapport requis.
6. Autorisez votre application en accédant à console.cloud.google.com et en recherchant l'API Google Analytics Data, puis en activant l'API.
 1. Accédez à la page API et services et choisissez Credentials > setup OAuth 2.0 Client IDs.
 2. Fournissez l'URL de redirection en ajoutant l'URL de AWS Glue redirection.
7. Copiez l'identifiant du client et le secret du client, qui nécessiteront des informations supplémentaires pour créer une connexion.

Limites et considérations

Les limites du connecteur Google Analytics 4 sont les suivantes :

- Pour l'entité Core Report, seuls 9 champs de dimension et 10 champs métriques sont autorisés à envoyer une demande. Si le nombre de champs autorisés est dépassé, la demande échouera et le connecteur enverra un message d'erreur.
- Pour l'entité Realtime Report, seuls les champs de 4 dimensions sont autorisés à envoyer une demande. Si le nombre de champs autorisés est dépassé, la demande échouera et le connecteur enverra un message d'erreur.
- Google Analytics 4 est un outil gratuit en version bêta. Il y aura donc des mises à jour régulières sur les nouvelles fonctionnalités, l'amélioration des entités, l'ajout de nouveaux champs et la désapprobation des champs existants.
- Les champs du rapport de base étant remplis de manière dynamique, des champs seront ajoutés, dépréciés et renommés, et l'imposition de nouvelles limites aux champs peut être effectuée à tout moment.
- La date de début par défaut est de 30 jours et la date de fin est hier (un jour avant la date actuelle), et ces dates seront remplacées dans le code d'expression du filtre si l'utilisateur a défini la valeur OU si le flux est incrémentiel.

- Selon la documentation, l'entité de rapport en temps réel renvoie 10 000 enregistrements si la limite n'est pas dépassée dans la demande, sinon l'API renvoie un maximum de 250 000 lignes par demande, quel que soit le nombre que vous demandez. Pour plus d'informations, voir [Méthode : propriétés. runRealtimeReport](#) dans la documentation de Google Analytics.
- L'entité Real-Time Report ne prend pas en charge la partition basée sur les enregistrements car elle ne prend pas en charge la pagination. De plus, il ne prend pas en charge la partition basée sur les champs car aucun des champs ne répond aux critères définis.
- En raison de la limitation du nombre de champs pouvant être transmis dans une demande. Nous définissons les champs de dimension et de métrique par défaut dans les limites indiquées. Si « Tout sélectionner » est sélectionné, seules les données de ces champs prédéterminés seront récupérées.
 - Rapport de base
 - Conformément aux limites du SAAS, les demandes sont autorisées jusqu'à 9 dimensions et jusqu'à 10 mesures uniquement (c'est-à-dire qu'une demande peut contenir un maximum de 19 champs (métriques + dimension).
 - Conformément à l'implémentation - Si l'utilisateur utilise SELECT_ALL ou sélectionne plus de 25 champs, les champs par défaut seront transmis dans la demande.
 - Les champs suivants sont considérés comme des champs par défaut pour Core Report : « country », « city », « EventName », « cityID », « browser », « date », « CurrencyCode », « DeviceCategory », « TransactionId », « active1 », « active28 », « active7 », DayUsers « ActiveUsers », « User », DayUsers « Engagement » Sessions », DayUsers « Nombre d'événements », averagePurchaseRevenue « Taux d'engagement » averageRevenuePer. averageSessionDuration
 - Rapport en temps réel
 - Conformément aux limites imposées par le SAAS, les demandes sont autorisées jusqu'à 4 dimensions.
 - Si l'utilisateur transmet SELECT_ALL ou si les champs sélectionnés sont supérieurs à 15, les champs par défaut seront transmis dans la demande.
 - Les champs suivants sont considérés comme des champs par défaut pour le RealTime rapport : « country », « DeviceCategory », « city », « CityID », « ActiveUsers », « conversions », « EventCount », « ». screenPageViews
- Dans l'entité Core-Report, si la partition sur le champ de date et le filtre sur StartDate sont présents simultanément. Dans ce cas, la valeur DateRange est remplacée par la valeur du filtre StartDate,

mais comme la partition doit toujours être la priorité, le filtre `StartDate` est supprimé si la partition sur le champ de date est déjà présente.

- Comme `CohortSpecs` fait désormais également partie du corps de demande de rapport de base, nous avons amélioré l'entité de rapport de base actuelle pour inclure la prise en charge de l'attribut `CohortSpec`. Dans le corps de la requête `CohortSpecs`, presque tous les champs nécessitent une saisie par l'utilisateur. Pour résoudre ce problème, nous avons défini des valeurs par défaut pour ces attributs/champs et avons prévu des dispositions permettant à l'utilisateur de remplacer ces valeurs si nécessaire.

FieldName	Valeurs par défaut	Exemple de requête pour transmettre les options <code>FilterPredicate</code> afin de remplacer les valeurs par défaut
<code>startDate</code>	Il y a 30 jours à compter de la date actuelle	« Date de début comprise entre « 2023-05-09 » et « 2023-05-10 »
<code>endDate</code>	Il y a 1 jour à compter de la date actuelle	« Date de début comprise entre « 2023-05-09 » et « 2023-05-10 »
<code>startOffset</code>	0	Offset de départ = 2
<code>EndOffset</code>	1	Offset final = 10
<code>granularité</code>	TOUS LES JOURS	<code>GRANULARity="HEBDO MADAIRE »</code>

- Vous pouvez également passer tous ces filtres ensemble en une seule fois ou avec d'autres filtres.
 - Exemple 1 - `FilterPredicate` : `StartDate` entre « 2023-05-09 » et « 2023-05-10 » ET `StartOffset`=1 ET `EndOffset`=2 ET `GRANULARity`="WEEKLY »
 - Exemple 2 - `FilterPredicate` : `city`= « xyz » ET `startOffset`=1 ET `endOffset`=2 ET `GRANULARity`="WEEKLY »
- Dans le cadre d'une demande de cohorte :

- Si « cohortNthMonth » est transmis dans la demande, la valeur de granularité interne sera définie comme « MENSUELLE »
- De même, si « cohortNthWeek » est transmis, la valeur de granularité sera définie comme « HEBDOMADAIRE »
- Et, pour « cohortNthDay », la valeur de granularité sera définie comme « TOUS LES JOURS ». Pour plus d'informations, consultez :
 - <https://developers.google.com/analytics/devguides/reporting/data/v1/advanced>
 - <https://developers.google.com/analytics/devguides/reporting/data/v1/rest/v1beta/CohortSpec>
- Il est permis à l'utilisateur de remplacer la valeur par défaut de DateRange et de granularité. Reportez-vous au tableau ci-dessus.

Connexion à Google BigQuery en AWS Glue Studio

Note

Vous pouvez utiliser ... AWS Glue pour que Spark puisse lire et écrire dans des tables de Google BigQuery dans AWS Glue Versions 4.0 et ultérieures. Pour configurer Google BigQuery avec AWS Glue jobs programmatiquement, voir [BigQuery connexions](#).

AWS Glue Studio fournit une interface visuelle pour se connecter BigQuery, créer des tâches d'intégration de données et les exécuter sur le AWS Glue Studio environnement d'exécution Spark sans serveur.

Lors de la création d'une connexion à Google BigQuery In AWS Glue Studio, une connexion unifiée est créée. Pour de plus amples informations, veuillez consulter [Considérations](#).

Au lieu de créer un secret avec les informations d'identification dans un format spécifique{"credentials": "base64 encoded JSON"}, désormais avec une connexion unifiée à Google BigQuery, vous pouvez créer un secret qui inclut directement le JSON de Google : BigQuery. {"type": "service-account", ...}

Rubriques

- [Création d'une BigQuery connexion](#)
- [Création d'un nœud BigQuery source](#)

- [Création d'un nœud BigQuery cible](#)
- [Options avancées](#)

Création d'une BigQuery connexion

Pour vous connecter à Google BigQuery depuis AWS Glue, vous devez créer et stocker vos informations d'identification Google Cloud Platform dans un AWS Secrets Manager secret, puis associer ce secret à une BigQuery AWS Glue connexion Google.

Pour configurer une connexion à BigQuery :

1. Dans Google Cloud Platform, créez et identifiez les ressources pertinentes :
 - Créez ou identifiez un projet GCP contenant des BigQuery tables auxquelles vous souhaitez vous connecter.
 - Activez l' BigQuery API. Pour plus d'informations, voir [Utiliser l'API BigQuery Storage Read pour lire les données des tables](#).
2. Dans Google Cloud Platform, créez et exportez les informations d'identification du compte de service :

Vous pouvez utiliser l'assistant BigQuery d'identification pour accélérer cette étape : [créer des informations d'identification](#).

Pour créer un compte de service dans GCP, suivez le didacticiel disponible dans la section [Créer des comptes de service](#).

- Lorsque vous sélectionnez un projet, sélectionnez le projet contenant votre BigQuery tableau.
- Lorsque vous sélectionnez des rôles GCP IAM pour votre compte de service, ajoutez ou créez un rôle qui accordera les autorisations appropriées pour exécuter des BigQuery tâches de lecture, d'écriture ou de création BigQuery de tables.

Pour créer des informations d'identification pour votre compte de service, suivez le didacticiel disponible dans la section [Créer une clé de compte de service](#).

- Lorsque vous sélectionnez le type de clé, sélectionnez JSON.

Vous devriez maintenant avoir téléchargé un fichier JSON contenant les informations d'identification de votre compte de service. Il doit ressembler à l'exemple ci-dessous.

```
{
  "type": "service_account",
  "project_id": "*****",
  "private_key_id": "*****",
  "private_key": "*****",
  "client_email": "*****",
  "client_id": "*****",
  "auth_uri": "https://accounts.google.com/o/oauth2/auth",
  "token_uri": "https://oauth2.googleapis.com/token",
  "auth_provider_x509_cert_url": "https://www.googleapis.com/oauth2/v1/certs",
  "client_x509_cert_url": "*****",
  "universe_domain": "googleapis.com"
}
```

3. Dans AWS Secrets Manager, créez un secret à l'aide du fichier d'informations d'identification que vous avez téléchargé. Vous pouvez choisir l'onglet Plaintext et coller le contenu du fichier au format JSON. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.
4. Dans le catalogue de AWS Glue données, créez une connexion en suivant les étapes décrites dans <https://docs.aws.amazon.com/glue/latest/dg/console-connections.html>. Après avoir créé la connexion, conservez le nom de la connexion pour l'étape suivante. *connectionName*
 - Lorsque vous sélectionnez un type de connexion, sélectionnez Google BigQuery.
 - Lorsque vous sélectionnez un AWS secret, fournissez *secretName*.
5. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire *secretName*.
6. Dans la configuration de votre AWS Glue tâche, fournissez *connectionName* une connexion réseau supplémentaire.

Création d'un nœud BigQuery source

Prérequis

- Une connexion BigQuery de type AWS Glue Data Catalog

- Un AWS Secrets Manager secret pour vos BigQuery informations d'identification Google, utilisées par la connexion.
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.
- Le nom et le jeu de données de la table et du projet Google Cloud correspondant que vous souhaitez lire.

Ajouter une source BigQuery de données

Pour ajouter une source de données — BigQuery nœud :

1. Choisissez la connexion pour votre source BigQuery de données. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Créer une BigQuery connexion. Pour en savoir plus, consultez [Overview of using connectors and connections](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Identifiez les BigQuery données que vous souhaitez lire, puis choisissez une option BigQuery Source

- Choisissez une seule table : cela vous permet d'extraire toutes les données d'une table.
- Saisissez une requête personnalisée : cela vous permet de personnaliser les données extraites en fournissant une requête.

3. Décrivez les données que vous souhaitez lire.

(Obligatoire) Définissez le Projet parent sur le projet contenant votre table, ou sur un projet parent de facturation, le cas échéant.

Si vous avez choisi une seule table, attribuez à Table le nom d'une BigQuery table Google au format suivant : [dataset].[table]

Si vous avez choisi une requête, indiquez-la à Requête. Dans votre requête, faites référence aux tables avec leur nom de table complet, au format suivant : [project].[dataset].[tableName].

4. Fournir des BigQuery propriétés

Si vous avez choisi une seule table, vous n'avez pas besoin de fournir de propriétés supplémentaires.

Si vous avez choisi une requête, vous devez fournir les BigQuery propriétés Google personnalisées suivantes :

- Définissez `viewsEnabled` sur `true`.
- Définissez `materializationDataset` sur un jeu de données. Le principal GCP authentifié par les informations d'identification fournies via la AWS Glue connexion doit être en mesure de créer des tables dans cet ensemble de données.

Création d'un nœud BigQuery cible

Prérequis

- Une connexion BigQuery de type AWS Glue Data Catalog
- Un AWS Secrets Manager secret pour vos BigQuery informations d'identification Google, utilisées par la connexion.
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.
- Le nom et le jeu de données de la table et du projet Google Cloud correspondant dans lequel vous souhaitez écrire.

Ajouter une cible BigQuery de données

Pour ajouter une cible de données — BigQuery nœud :

1. Choisissez la connexion pour votre cible BigQuery de données. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Créer une BigQuery connexion. Pour en savoir plus, consultez [Overview of using connectors and connections](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Identifiez la BigQuery table dans laquelle vous souhaitez écrire, puis choisissez une méthode d'écriture.
 - Direct : écrit BigQuery directement sur le site à l'aide de l'API BigQuery Storage Write.
 - Indirect : écrit dans Google Cloud Storage, puis copie dans BigQuery.

Si vous souhaitez écrire indirectement, indiquez un emplacement GCS de destination avec un Compartiment GCS temporaire. Vous devrez fournir une configuration supplémentaire dans votre AWS Glue connexion. Pour plus d'informations, consultez la section [Utilisation de l'écriture indirecte avec Google BigQuery](#).

3. Décrivez les données que vous souhaitez lire.

(Obligatoire) Définissez le Projet parent sur le projet contenant votre table, ou sur un projet parent de facturation, le cas échéant.

Si vous avez choisi une seule table, attribuez à Table le nom d'une BigQuery table Google au format suivant : [dataset].[table]

Options avancées

Vous pouvez fournir des options avancées lors de la création d'un BigQuery nœud. Ces options sont les mêmes que celles disponibles lors de la programmation AWS Glue de scripts Spark.

Voir [BigQuery la référence des options de connexion](#) dans le guide du AWS Glue développeur.

Connexion à la console de recherche Google

Google Search Console est une plateforme gratuite mise à la disposition des propriétaires de sites Web pour surveiller la façon dont Google voit le site et optimiser sa présence organique. Cela inclut l'affichage des domaines de référence, les performances des sites mobiles, les résultats de recherche enrichis et les requêtes et pages les plus fréquentées. Si vous utilisez la console de recherche Google, vous pouvez vous connecter AWS Glue à votre compte Google Search Console. Vous pouvez utiliser la console de recherche Google comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données de la console de recherche Google vers AWS des services ou d'autres applications compatibles.

Rubriques

- [AWS Glue support pour Google Search Console](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de la console de recherche Google](#)
- [Configuration des connexions à la console de recherche Google](#)
- [Lecture à partir des entités de la console de recherche Google](#)

- [Options de connexion à la console de recherche Google](#)
- [Limitations de la console de recherche Google](#)

AWS Glue support pour Google Search Console

AWS Glue prend en charge la console de recherche Google comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données à partir de la console de recherche Google.

Soutenu en tant que cible ?

Non

Versions de l'API Google Search Console prises en charge

Les versions suivantes de l'API Google Search Console sont prises en charge :

- v3

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```



```
]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de la console de recherche Google

Avant de pouvoir AWS Glue transférer des données depuis la console de recherche Google, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous possédez un compte Google Search Console.
- Vous possédez un compte Google Cloud Platform et un projet Google Cloud.
- Dans votre projet Google Cloud, vous avez activé l'API Google Search Console.
- Dans votre projet Google Cloud, vous avez configuré un écran de OAuth consentement pour les utilisateurs externes. Pour plus d'informations, consultez la section [Configuration de votre écran de OAuth consentement](#) dans l'aide de la console Google Cloud Platform.
- Dans votre projet Google Cloud, vous avez configuré un identifiant client OAuth 2.0. Consultez la section [Configuration OAuth 2.0](#) pour connaître les informations d'identification du client AWS Glue qui permettent d'accéder à vos données en toute sécurité lorsqu'il effectue des appels authentifiés vers votre compte.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Google Search Console. Pour les connexions classiques, vous n'avez rien d'autre à faire dans la console de recherche Google.

Configuration des connexions à la console de recherche Google

La console de recherche Google prend en charge le type de subvention `AUTHORIZATION_CODE` pour `OAuth2`. Le type de subvention détermine le mode AWS Glue de communication avec la console de recherche Google pour demander l'accès à vos données.

- Ce type de subvention est considéré comme « à trois étapes » `OAuth` car il repose sur la redirection des utilisateurs vers un serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console.
- Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans la console de recherche Google et de fournir leur propre identifiant client et leur secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers la console de recherche Google pour se connecter et autoriser AWS Glue l'accès à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- Pour consulter la documentation publique de la console de recherche Google sur la création d'une application connectée pour le `OAuth` flux de code d'autorisation, voir [Utilisation de la OAuth version 2.0 pour accéder à Google APIs](#).

Pour configurer une connexion à la console de recherche Google :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir le secret du consommateur de l'application connectée avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
 - b. Remarque : vous devez créer un secret pour vos connexions dans AWS Glue.
1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Google Search Console.

- b. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- c. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
- d. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture à partir des entités de la console de recherche Google

Prérequis

Un objet de la console de recherche Google dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Analyses de recherche	Oui	Oui	Non	Oui	Non
Sites	Non	Non	Non	Oui	Non
Plans du site	Non	Non	Non	Oui	Non

Exemple :

```
googleSearchConsole_read = glueContext.create_dynamic_frame.from_options(
    connection_type="googlesearchconsole",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v3"
    }
)
```

Détails de l'entité et des champs de la console de recherche Google :

La console de recherche Google fournit des points de terminaison permettant de récupérer les métadonnées de manière dynamique pour les entités prises en charge. Par conséquent, le support de l'opérateur est capturé au niveau du type de données.

Entité	Champ	Type de données	Opérateurs pris en charge	Remarque
Analyses de recherche	clés	Liste	N/A	
	clics	Double	N/A	
	impressions	Double	N/A	
	ctr	BigDecimal	N/A	Pour le BigDecimal type de données, la

Entité	Champ	Type de données	Opérateurs pris en charge	Remarque
				valeur « 0 » est formatée comme « 0E-18 »
	position	Double	N/A	
	date de début_fin	Date	BETWEEN	La valeur par défaut pour start_end_date est comprise entre <30 days ago from the current date>ET <yesterday : that is, 1 day ago from the current date> Remarque : s'attend à ce que vous transmettiez une valeur de date UTC. Exemple : date de fin de début comprise entre « 01-01-01 » ET « 2024-09-09 »
	country	Chaîne	EQUAL_TO, NOT_EQUAL_TO, CONTIENT	Les valeurs valides sont « IND », « CAN », etc.

Entité	Champ	Type de données	Opérateurs pris en charge	Remarque
	type	Chaîne	EQUAL_TO, NOT_EQUAL_TO	Les valeurs valides sont « discover », « GoogleNews », « news », « image », « video », « web »
	Apparence de recherche	Chaîne	EQUAL_TO, NOT_EQUAL_TO, CONTIENT	Voir Apparence de la recherche pour une liste de valeurs valides.
	appareil	Chaîne	EQUAL_TO, NOT_EQUAL_TO, CONTIENT	Les valeurs valides sont « DESKTOP », « MOBILE », « TABLET »
	dimensions	Chaîne	EQUAL_TO	Les valeurs valides sont « country », « device »
	page	Chaîne	EQUAL_TO, NOT_EQUAL_TO, CONTIENT	
	query	Chaîne	EQUAL_TO, NOT_EQUAL_TO, CONTIENT	

Entité	Champ	Type de données	Opérateurs pris en charge	Remarque
	État des données	Chaîne	EQUAL_TO	Les valeurs valides sont « all » et « final »
Sites	URL du site	Chaîne	N/A	
	Niveau d'autorisation	Chaîne	N/A	
Plans du site	path	Chaîne	N/A	
	type	Chaîne	N/A	
	Dernière soumission	DateTime	N/A	
	est en attente	Booléen	N/A	
	isSitemapsIndex	Booléen	N/A	
	Téléchargé pour la dernière fois	DateTime	N/A	
	avertissements	Long	N/A	
	errors	Long	N/A	
	contenu	Liste	N/A	

Note

Pour obtenir une liste actualisée des valeurs valides pour les filtres, consultez la documentation relative à l'API [Google Search Console](#).
Le champ `start_end_date` est une combinaison de `start_date` et `end_date`.

Requêtes de partitionnement

Le partitionnement basé sur des filtres et le partitionnement basé sur des enregistrements ne sont pas pris en charge.

Options de connexion à la console de recherche Google

Les options de connexion pour la console de recherche Google sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans la console de recherche Google.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API REST de la Google Search Console que vous souhaitez utiliser.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**<30 days ago from current date><yesterday : that is, 1 day ago from the current date>(String) - Par défaut : « start_end_date between AND ». Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : « start_end_date between <30 days ago from current date>AND <yesterday : that is, 1 day ago from the current date> » Utilisé pour Read. Requête SQL Spark complète.
- **INSTANCE_URL**(String) - Utilisé pour la lecture. URL d'instance Google Search Console valide.

Limitations de la console de recherche Google

Les restrictions ou remarques suivantes s'appliquent à la console de recherche Google :

- La console de recherche Google impose des limites d'utilisation à l'API. Pour plus d'informations, consultez la section [Limites d'utilisation](#).
- Lorsqu'aucun filtre n'est appliqué à l'Analyticsentité, l'API résume tous les clics, impressions, CTR et autres données pour l'ensemble de votre site dans la plage de dates par défaut spécifiée et les présente sous forme d'enregistrement unique.
- Pour décomposer les données en segments plus petits, vous devez ajouter des dimensions à votre requête. Dimensions indique à l'API comment vous souhaitez segmenter vos données.
 - Par exemple, si vous ajoutez, `filterPredicate: dimensions="country"` vous obtiendrez un enregistrement pour chaque pays où votre site a reçu du trafic au cours de la période spécifiée.

- Exemple pour transmettre plusieurs dimensions :`filterPredicate: dimensions="country" AND dimensions="device" AND dimensions="page"`. Dans ce cas, vous obtiendrez une ligne dans la réponse pour chaque combinaison unique de ces trois dimensions.
- Les valeurs par défaut sont définies pour les `dataState` champs `start_end_date` et.

Nom de champ	Expression de filtre par défaut	Expression pour remplacer les valeurs par défaut
date de début_fin	<30 days ago from current date> start_end_date entre ET <yesterday : that is, 1 day ago from the current date>	date_de_début comprise entre « 2024-01-01 » ET « 2024-05-05 »
État de la date	DataState="Tout »	DataState="final »

Connexion à Google Sheets

Google Sheets est un tableur en ligne qui vous permet d'organiser de grandes quantités de données, de créer des rapports personnalisés, d'automatiser les calculs et de collaborer avec d'autres personnes. Si vous utilisez Google Sheets, vous pouvez vous connecter AWS Glue à votre compte Google Sheets. Vous pouvez ensuite utiliser Google Sheets comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre Google Sheets et AWS des services ou d'autres applications compatibles.

Rubriques

- [AWS Glue support pour Google Sheets](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Google Sheets](#)
- [Configuration des connexions Google Sheets](#)
- [Lecture à partir d'entités Google Sheets](#)
- [Options de connexion à Google Sheets](#)
- [Configurer le OAuth flux de code d'autorisation pour Google Sheets](#)
- [Limitations du connecteur Google Sheets](#)

AWS Glue support pour Google Sheets

AWS Glue prend en charge Google Sheets comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Google Sheets.

Soutenu en tant que cible ?

Non

Versions de l'API Google Sheets prises en charge

API Google Sheets v4 et API Google Drive v3

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Vous pouvez également utiliser les politiques IAM gérées suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM,

CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Google Sheets

Avant de pouvoir AWS Glue effectuer un transfert depuis Google Sheets, vous devez remplir les conditions suivantes :

Configuration requise

- Vous avez un compte Google Sheets avec e-mail et mot de passe.
- Votre compte Google Sheets est activé pour accéder à l'API. Toute utilisation de l'API Google Sheets est disponible sans frais supplémentaires.
- Votre compte Google Sheets vous permet d'installer des applications connectées. Si vous n'avez pas accès à cette fonctionnalité, contactez votre administrateur Google Sheets.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Google Sheets.

Configuration des connexions Google Sheets

Pour configurer une connexion à Google Sheet, procédez comme suit :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour le type de AuthorizationCode subvention :
 - Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :

- a. Lorsque vous sélectionnez une source de données, sélectionnez Google Sheets.
 - b. Fournissez l'environnement Google Sheets.
 - i. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - ii. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

AUTHORIZATION_CODE Type de subvention

Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. La AWS Glue console redirige l'utilisateur vers Google Sheets où il doit se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Google Sheets.

Les utilisateurs peuvent choisir de créer leur propre application connectée dans Google Sheets et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Google Sheets pour se connecter et autoriser AWS Glue l'accès à leurs ressources.

Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.

Pour plus d'informations, consultez la [documentation publique de Google Sheets sur la création d'une application connectée pour le OAuth flux de code d'autorisation](#).

Lecture à partir d'entités Google Sheets

Prérequis

- Un Google SpreadSheet que vous aimeriez lire. Vous aurez besoin de l' SpreadSheet ID et du TabName de la feuille de calcul.

Détails des entités et des champs Google Sheets :

Entité	Type de données	Opérateurs pris en charge
Feuille de calcul	Chaîne	N/A (le filtre n'est pas pris en charge)

Exemple

```
googleSheets_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="googlesheets",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "{SpreadSheetID}#{SheetTabName}",  
        "API_VERSION": "v4"  
    }  
)
```

Requêtes de partitionnement

Pour le partitionnement de base d'enregistrements uniquement, vous NUM_PARTITIONS pouvez fournir des options Spark supplémentaires si vous souhaitez utiliser la simultanéité dans Spark. Avec ce paramètre, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

Exemple avec NUM_PARTITIONS

```
googlesheets_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="googlesheets",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "{SpreadSheetID}#{SheetTabName}",  
        "API_VERSION": "v4",  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Options de connexion à Google Sheets

Les options de connexion pour Google Sheets sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le SpreadSheet ID et sheetTabName dans Google Sheets. Exemple: {SpreadSheetID}#{SheetTabName}.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Google Sheets Rest que vous souhaitez utiliser.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Configurer le OAuth flux de code d'autorisation pour Google Sheets

Prérequis

- Un compte Google auquel vous pouvez vous connecter pour utiliser l'application Google Sheets. Dans votre compte Google, Google Sheets contient les données que vous souhaitez transférer.
- Un compte Google Cloud Platform et un projet Google Cloud. Consultez [Créer un projet Google Cloud](#) pour plus de détails.

Pour configurer votre compte Google et obtenir des informations d'identification OAuth 2.0 :

1. Une fois le projet Google Cloud configuré, activez l'API Google Sheets et Google Drive APIs dans le projet. Pour connaître les étapes permettant de les activer, consultez la section [Activer et désactiver APIs](#) dans l'aide de la console API pour Google Cloud Platform.
2. Configurez ensuite un écran de OAuth consentement pour les utilisateurs externes. Pour plus d'informations sur l'écran de OAuth consentement, consultez la section [Configuration de votre écran de OAuth consentement](#) dans l'aide de la console Google Cloud Platform.
3. Dans l'écran de OAuth consentement, ajoutez les champs d'application suivants :
 - [Champ d'application en lecture seule de l'API Google Sheets](#)
 - [Champ d'application en lecture seule de l'API Google Drive](#)

Pour plus d'informations sur ces étendues, consultez la section [Scopes OAuth 2.0 pour Google APIs](#) dans la documentation de Google Identity.

4. Générez un identifiant client OAuth 2.0 et un secret. Pour connaître les étapes de création de cet ID client, consultez la section [Configuration de la OAuth version 2.0](#) dans l'aide de la console Google Cloud Platform.

L'ID client OAuth 2.0 doit comporter une ou plusieurs redirections autorisées URLs.

URLs Les redirections ont le format suivant :

- `https ://<aws-region>.console.aws.amazon. com/gluestudio/oauth`

5. Notez l'ID client et le secret du client dans les paramètres de votre ID client OAuth 2.0.

Limitations du connecteur Google Sheets

Les limites du connecteur Google Sheets sont les suivantes :

- Le connecteur Google Sheets ne prend pas en charge les filtres. Par conséquent, le partitionnement basé sur des filtres ne peut pas être pris en charge.
- Dans le partitionnement de base d'enregistrements, aucune disposition ne permet de renvoyer le nombre exact d'enregistrements par SAAS. Par conséquent, il peut arriver que des fichiers contenant des enregistrements vides soient créés.

- Étant donné que le connecteur Google Sheets ne prend pas en charge le partitionnement basé sur des filtres, `partitionFieldLowerbound`, et `upperbound` sont pas des options de connexion valides. Si ces options sont fournies, la AWS Glue tâche est censée échouer.
- Il est essentiel de désigner la première ligne de la feuille comme ligne d'en-tête pour éviter les problèmes de traitement des données.
 - Si elle n'est pas fournie, la ligne d'en-tête sera remplacée par `Unnamed:1`, `Unnamed:2`, `Unnamed:3`... si la feuille contient des données dont la première ligne est vide.
 - Si une ligne d'en-tête est fournie, les noms de colonnes vides seront remplacés par `Unnamed:<number of column>`. Par exemple, si la ligne d'en-tête est `['ColumnName1', 'ColumnName2', '', '', 'ColumnName5', 'ColumnName6']`, elle deviendra `['ColumnName1', 'ColumnName2', 'Unnamed:3', 'Unnamed:4', 'ColumnName5', 'ColumnName6']`.
- Le connecteur Google Sheets ne prend pas en charge le transfert incrémentiel.
- Le connecteur Google Sheets ne prend en charge que le type de données String.
- Les en-têtes dupliqués d'une feuille seront renommés de manière itérative avec un suffixe numérique. Les noms d'en-tête fournis par l'utilisateur auront priorité lors du changement de nom des en-têtes dupliqués. Par exemple, si la ligne d'en-tête est `["Name », « », « Name », null, « Unnamed:6", «"]`, elle deviendra : `["Name », « Unnamed:2 », « Name1 », « Unnamed:4 », « Unnamed:6 », « Unnamed:61 »]`.
- Le connecteur Google Sheets ne prend pas en charge les espaces pour un `TabName`.
- Le nom d'un dossier ne peut pas comporter les caractères spéciaux suivants :
 - #
 - /

Connexion à HubSpot

HubSpotLa plateforme CRM dispose de tous les outils et intégrations dont vous avez besoin pour le marketing, les ventes, la gestion de contenu et le service client.

- Marketing Hub : un logiciel de marketing qui vous aide à augmenter le trafic, à convertir plus de visiteurs et à exécuter des campagnes de marketing entrant complètes à grande échelle.
- Sales Hub - Logiciel CRM pour les ventes qui vous aide à mieux comprendre les prospects, à automatiser vos tâches et à conclure plus de ventes plus rapidement.

- Service Hub : un logiciel de service client qui vous aide à entrer en contact avec les clients, à dépasser leurs attentes et à en faire des promoteurs capables de développer votre activité.
- Operations Hub : logiciel d'exploitation qui synchronise vos applications, nettoie et crée les données clients, et automatise les processus, afin que tous vos systèmes et équipes travaillent mieux ensemble.

Rubriques

- [AWS Glue support pour HubSpot](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration HubSpot](#)
- [Configuration des HubSpot connexions](#)
- [Lecture à partir d' HubSpot entités](#)
- [HubSpot options de connexion](#)
- [Limitations et remarques relatives au HubSpot connecteur](#)

AWS Glue support pour HubSpot

AWS Glue prend en charge HubSpot les éléments suivants :

Supportée en tant que source ?

Oui — Synchronisation et asynchronisation. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données à partir de HubSpot.

Soutenu en tant que cible ?

Non.

Versions HubSpot d'API prises en charge

Les versions HubSpot d'API suivantes sont prises en charge :

- v1
- v2
- v3
- v4

Pour la prise en charge des entités par version spécifique, voir [Entités prises en charge pour Sync source](#) et [Entités prises en charge pour la source asynchrone](#).

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration HubSpot

Avant de pouvoir AWS Glue transférer des données depuis HubSpot, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Tu as un HubSpot compte. Pour de plus amples informations, veuillez consulter [Création d'un HubSpot compte](#).
- Votre HubSpot compte est activé pour accéder à l'API.
- Vous devez disposer d'une application sous votre compte de HubSpot développeur qui fournit les informations d'identification du client qui AWS Glue permettent d'accéder à vos données en toute sécurité lorsqu'il passe des appels authentifiés vers votre compte. Pour de plus amples informations, veuillez consulter [Création d'une application HubSpot pour développeurs](#).

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre HubSpot compte. Pour les connexions classiques, vous n'avez rien d'autre à faire HubSpot.

Création d'un HubSpot compte

Pour créer un HubSpot compte :

1. Accédez à l' [SignUp URL du HubSpot CRM](#).
2. Entrez votre adresse e-mail et choisissez Vérifier l'adresse e-mail (vous pouvez également choisir de vous inscrire avec un compte Google, Microsoft ou Apple).
3. Vérifiez dans votre boîte de réception le code de vérification provenant de HubSpot.
4. Entrez le code de vérification à 6 chiffres et cliquez sur Suivant.
5. Entrez un mot de passe et cliquez sur Suivant.
6. Entrez vos prénom et nom de famille et cliquez sur Suivant, ou inscrivez-vous en utilisant le lien S'inscrire avec Google.
7. Entrez votre secteur d'activité et cliquez sur Suivant.
8. Entrez votre rôle professionnel et cliquez sur Suivant.
9. Entrez le nom de votre entreprise et cliquez sur Suivant.

- 10.Sélectionnez la taille de votre entreprise (nombre d'employés travaillant dans votre entreprise) et cliquez sur Suivant.
- 11Accédez au site Web de votre entreprise et cliquez sur Suivant.
- 12.Sélectionnez l'endroit où vos données doivent être hébergées (États-Unis d'Amérique ou Europe) et cliquez sur Créer un compte.
- 13.Sélectionnez le but de la création de votre compte et cliquez sur Suivant.
- 14.Choisissez Connect Google Account ou choisissez d'ajouter vous-même des contacts pour les associer à votre HubSpot compte.
- 15.Connectez-vous à votre compte Google si vous avez choisi l'option Connect Google Account pour associer vos contacts et commencer à utiliser votre HubSpot compte.

Création d'une application HubSpot pour développeurs

Les comptes de développeur d'applications sont destinés à créer et à gérer des applications, des intégrations et des comptes de test pour développeurs. Ils vous permettent également de créer et de gérer des listes sur App Marketplace. Toutefois, les comptes de développeur d'applications et leurs comptes de test associés ne sont pas connectés à un HubSpot compte standard. Ils ne peuvent pas synchroniser les données ou les actifs depuis ou vers un autre HubSpot compte. Pour obtenir l'ID client et le secret du client, vous devez créer un compte de développeur.

1. Accédez à <https://developers.hubspot.com/>
2. Choisissez Créer un compte développeur et faites défiler l'écran vers le bas.
3. Il vous sera demandé si vous souhaitez créer un compte de développeur d'applications, un compte d'application privé ou un compte CMS Developer Sandbox. Choisissez Créer un compte pour développeurs d'applications.
4. Puisque vous avez déjà créé un compte auprès de cet utilisateur HubSpot, vous pouvez choisir Continuer avec cet utilisateur.
5. Cliquez sur Démarrer l'inscription.
6. Entrez votre rôle de Job et cliquez sur Next.
7. Donnez un nom à votre compte de développeur et cliquez sur Suivant, puis sur Ignorer.
8. Sélectionnez Create App (Créer une application).
9. Une fois votre application créée, choisissez Auth.
- 10.Sous Auth, notez l'ID du client et le secret du client.

- 11 Ajoutez l'URL de redirection spécifique à votre région sous la forme `https://<aws-region>.console.aws.amazon.com/gluestudio/oauth`. For example, add `https://us-east-1.console.aws.amazon.com/gluestudio/oauth` pour la région us-east-1.
- 12 Faites défiler la page vers le bas et trouvez des scopes. Il existe deux types de champs d'application que vous devez sélectionner sous les rubriques « CRM » et « Standard ».
- 13 Ajoutez les étendues suivantes :

```
content
automation
oauth
crm.objects.owners.read
forms
tickets
crm.objects.contacts.write
e-commerce
crm.schemas.custom.read
crm.objects.custom.read
sales-email-read
crm.objects.custom.write
crm.objects.companies.write
crm.lists.write
crm.objects.companies.read
crm.lists.read
crm.objects.deals.read
crm.objects.deals.write
crm.objects.contacts.read
```

- 14 Cliquez sur Enregistrer et votre compte de développement est maintenant prêt à être utilisé.
- 15 Faites défiler la page ci-dessus pour trouver l'ID client.
- 16 Sur la même page, cliquez sur Afficher pour obtenir le secret du client.

Création d'un compte test pour HubSpot développeurs

Dans les comptes de développement d'applications, vous pouvez créer des comptes de test pour développeurs afin de tester des applications et des intégrations sans affecter les HubSpot données réelles. Les comptes de test pour développeurs ne reflètent pas les comptes de production, mais ont plutôt accès à un essai de 90 jours des versions Enterprise de Marketing, Sales, Service, CMS et Operations Hub, ce qui permet de tester la plupart des HubSpot outils et APIs.

1. Cliquez sur Accueil.

2. Cliquez sur Créer un compte de test.
3. Cliquez sur Créer un compte de test d'application.
4. Une nouvelle fenêtre apparaît. Entrez le nom du compte de test de l'application et cliquez sur Créer.

Votre compte de test d'application est maintenant créé.

Note

Le compte développeur est lié aux activités de développement telles que l'intégration d'API, et le compte de test de l'application est utilisé pour voir les données créées ou extraites par le compte développeur.

Configuration des HubSpot connexions

HubSpot prend en charge le type de subvention `AUTHORIZATION_CODE` pour `OAuth2`

- Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers un serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. L'utilisateur qui crée une connexion doit fournir les informations OAuth associées telles que l'ID client et le secret client pour son application HubSpot cliente. La AWS Glue console redirigera l'utilisateur vers l'HubSpot endroit où il doit se connecter et autorisera AWS Glue les autorisations demandées pour accéder à son HubSpot instance.
- Les utilisateurs peuvent toujours choisir de créer leur propre application connectée HubSpot et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés HubSpot vers pour se connecter et autoriser AWS Glue l'accès à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- Pour consulter HubSpot la documentation publique sur la création d'une application connectée pour le OAuth flux de code d'autorisation, consultez la section [Applications publiques](#).

Pour configurer une HubSpot connexion, procédez comme suit :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir le secret du consommateur de l'application connectée avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
 - b. Remarque : Vous devez créer un secret pour la connexion dans AWS Glue.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez HubSpot.
 - b. Fournissez l' HubSpot environnement.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.
4. Dans la configuration de votre AWS Glue tâche, fournissez `connectionName` une connexion réseau supplémentaire.

Lecture à partir d' HubSpot entités

Prérequis

Un HubSpot objet que vous aimeriez lire. Vous aurez besoin du nom de l'objet, tel que contact ou tâche. Le tableau suivant indique les entités prises en charge pour Sync source.

Entités prises en charge pour Sync source

Entité	Version de l'API	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Campagnes	v1	Non	Oui	Non	Oui	Non
Entreprises	v3	Oui	Oui	Oui	Oui	Oui
Contacts	v3	Oui	Oui	Oui	Oui	Oui
Listes de contacts	v1	Non	Oui	Non	Oui	Non
Offres	v3	Oui	Oui	Oui	Oui	Oui
Pipeline CRM (pipeline s de transacti ons)	v1	Non	Non	Non	Oui	Non
Événement s d'e-mail	v1	Non	Oui	Non	Oui	Non
Calls	v3	Oui	Oui	Oui	Oui	Oui
Remarques	v3	Oui	Oui	Oui	Oui	Oui
E-mails	v3	Oui	Oui	Oui	Oui	Oui
Réunions	v3	Oui	Oui	Oui	Oui	Oui

Entité	Version de l'API	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Tâches	v3	Oui	Oui	Oui	Oui	Oui
Courriels postaux	v3	Oui	Oui	Oui	Oui	Oui
Objets personnalisés	v3	Oui	Oui	Oui	Oui	Oui
Formulaires	v2	Non	Non	Non	Oui	Non
Propriétaires	v3	Non	Oui	Non	Oui	Non
Produits	v3	Oui	Oui	Oui	Oui	Oui
Tickets	v3	Oui	Oui	Oui	Oui	Oui
Flux de travail	v3	Non	Non	Non	Oui	Non
Associations	v4	Oui	Non	Non	Oui	Non
Étiquettes d'associations	v4	Non	Non	Non	Oui	Non

Exemple :

```

hubspot_read = glueContext.create_dynamic_frame.from_options(
    connection_type="hubspot",
    connection_options={
        "connectionName": "connectionName",

```

```
"ENTITY_NAME": "contact",
"API_VERSION": "v3"
}
```

Entités prises en charge pour la source asynchrone

Entité	Version de l'API	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Entreprises	v3	Oui	Non	Oui	Oui	Non
Contacts	v3	Oui	Non	Oui	Oui	Non
Offres	v3	Oui	Non	Oui	Oui	Non
Calls	v3	Oui	Non	Oui	Oui	Non
Remarques	v3	Oui	Non	Oui	Oui	Non
E-mails	v3	Oui	Non	Oui	Oui	Non
Réunions	v3	Oui	Non	Oui	Oui	Non
Tâches	v3	Oui	Non	Oui	Oui	Non
Courriels postaux	v3	Oui	Non	Oui	Oui	Non
Objets personnalisés	v3	Oui	Non	Oui	Oui	Non
Produits	v3	Oui	Non	Oui	Oui	Non
Tickets	v3	Oui	Non	Oui	Oui	Non

Exemple :

```
hubspot_read = glueContext.create_dynamic_frame.from_options(
```

```

connection_type="hubspot",
connection_options={
    "connectionName": "connectionName",
    "ENTITY_NAME": "contact",
    "API_VERSION": "v3",
    "TRANSFER_MODE": "ASYNC"
}

```

HubSpot détails de l'entité et du champ :

HubSpot API v4 :

Entité	Version de l'API	Champ	Type de données	Opérateurs pris en charge
Label d'association	v4	category	Chaîne	N/A
		typeld (IDtype)	Entier	N/A
		étiquette	Chaîne	N/A
Associations		from	Struct	N/A
		id	Chaîne	"="
		to	Liste	N/A

Note

Pour l'Associationsobjet, pour récupérer les associations entre deux objets, vous devez fournir le « from Id » (l'ID du premier objet) via un filtre obligatoire lors de la création d'une tâche. AWS Glue Si vous souhaitez récupérer des associations pour plusieurs IDs dans ce cas, vous devez en fournir plusieurs IDs dans la where clause. Par exemple : pour récupérer Associations les contacts IDs « 1 » et « 151 », vous devez fournir un filtre sous where id=1 AND id=151 la forme.

HubSpot API version 3 :

Entité	Champ	Type de données	Opérateurs pris en charge
Propriétaire	firstName	Chaîne	N/A
	lastName	Chaîne	N/A
	createdAt	DateTime	N/A
	archived	Booléen	N/A
	équipes	Liste	N/A
	id	Chaîne	N/A
	userId	Entier	N/A
	e-mail	Chaîne	N/A
	updatedAt	DateTime	N/A
Flux de travail	name	Chaîne	N/A
	id	Entier	N/A
	type	Chaîne	N/A
	enabled	Booléen	N/A
	Inséré à	Long	N/A
	updatedAt	Long	N/A
	contactListIds	Struct	N/A
	personaTagIds	Liste	N/A

Pour les entités suivantes, HubSpot fournit des points de terminaison permettant de récupérer les métadonnées de manière dynamique, afin que le support des opérateurs soit capturé au niveau du type de données pour chaque entité.

Note

DML_STATUS est un champ virtuel ajouté à chaque enregistrement lors de l'exécution afin de déterminer son statut (CRÉÉ/MIS À JOUR) en mode de synchronisation. L'CONTAINS/ LIKE opérateur n'est pas pris en charge en mode asynchrone.

Entité	Type de données	Opérateurs pris en charge
Contact	Entier	"=, !=, <, >, >=, <="
	Long	"=, !=, <, >, >=, <="
	Chaîne	« =, !=, COMME »
	Date	N/A
	DateTime	« entre »
	Booléen	"="
	Liste	N/A
	Struct	N/A
Société	Entier	"=, !=, <, >, >=, <="
	Long	"=, !=, <, >, >=, <="
	Chaîne	« =, !=, COMME »
	Date	N/A
	DateTime	« entre »
	Booléen	"="
	Liste	N/A
	Struct	N/A

Entité	Type de données	Opérateurs pris en charge
Deal	Entier	"=, !=, <, >, >=, <="
	Long	"=, !=, <, >, >=, <="
	Chaîne	« =, !=, COMME »
	Date	N/A
	DateTime	« entre »
	Booléen	"="
	Liste	N/A
	Struct	N/A
Billet	Entier	"=, !=, <, >, >=, <="
	Long	"=, !=, <, >, >=, <="
	Chaîne	« =, !=, COMME »
	Date	N/A
	DateTime	« entre »
	Booléen	"="
	Liste	N/A
	Struct	N/A
Produit (langue française non garantie)	Entier	"=, !=, <, >, >=, <="
	Long	"=, !=, <, >, >=, <="
	Chaîne	« =, !=, COMME »
	Date	N/A

Entité	Type de données	Opérateurs pris en charge
	DateTime	« entre »
	Booléen	"=
	Liste	N/A
	Struct	N/A
Objet personnalisé	Entier	"=, !=, <, >, >=, <="
	Long	"=, !=, <, >, >=, <="
	Chaîne	« =, !=, COMME »
	Date	N/A
	DateTime	« entre »
	Booléen	"=
	Liste	N/A
	Struct	N/A
Appelez	Entier	"=, !=, <, >, >=, <="
	Long	"=, !=, <, >, >=, <="
	Chaîne	« =, !=, COMME »
	Date	N/A
	DateTime	« entre »
	Booléen	"=
	Liste	N/A
	Struct	N/A

Entité	Type de données	Opérateurs pris en charge
E-mails	Entier	"=, !=, <, >, >=, <="
	Long	"=, !=, <, >, >=, <="
	Chaîne	« =, !=, COMME »
	Date	N/A
	DateTime	« entre »
	Booléen	"="
	Liste	N/A
	Struct	N/A
Réunion	Entier	"=, !=, <, >, >=, <="
	Long	"=, !=, <, >, >=, <="
	Chaîne	« =, !=, COMME »
	Date	N/A
	DateTime	« entre »
	Booléen	"="
	Liste	N/A
	Struct	N/A
Remarque	Entier	"=, !=, <, >, >=, <="
	Long	"=, !=, <, >, >=, <="
	Chaîne	« =, !=, COMME »
	Date	N/A

Entité	Type de données	Opérateurs pris en charge
	DateTime	« entre »
	Booléen	"=
	Liste	N/A
	Struct	N/A
Tâche	Entier	"=, !=, <, >, >=, <="
	Long	"=, !=, <, >, >=, <="
	Chaîne	« =, !=, COMME »
	Date	N/A
	DateTime	« entre »
	Booléen	"=
	Liste	N/A
	Struct	N/A
Courrier postal	Entier	"=, !=, <, >, >=, <="
	Long	"=, !=, <, >, >=, <="
	Chaîne	« =, !=, COMME »
	Date	N/A
	DateTime	« entre »
	Booléen	"=
	Liste	N/A
	Struct	N/A

HubSpot API v2 :

Entité	Champ	Type de données	Opérateurs pris en charge
Formulaire	ID du portail	Entier	N/A
	guide	Chaîne	N/A
	name	Chaîne	N/A
	méthode	Chaîne	N/A
	Classe CSS	Chaîne	N/A
	rediriger	Chaîne	N/A
	Soumettre le texte	Chaîne	N/A
	Notifier les destinataires	Chaîne	N/A
	createdAt	Long	N/A
	updatedAt	Long	N/A
	ignoreCurrentValues	Booléen	N/A
	effaçable	Booléen	N/A
	Message en ligne	Booléen	N/A
	Captcha activé	Booléen	N/A
	clonable	Booléen	N/A
	formFieldGroups	Liste	N/A
	editable	Booléen	N/A
	Supprimé à	Entier	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Nom du thème	Chaîne	N/A
	Identifiant du parent	Entier	N/A
	style	Chaîne	N/A
	isPublished	Booléen	N/A
	Publiez sur	Entier	N/A
	Dépublier sur	Entier	N/A
	Publié sur	Entier	N/A
	kickbackEmailWorkf lowId	Chaîne	N/A
	kickbackEmailsJson	Entier	N/A
	UID personnalisé	Chaîne	N/A
	createMarketableCo ntact	Booléen	N/A
	Modifier la version	Entier	N/A
	thankYouMessageJas on	Chaîne	N/A
	Couleur du thème	Chaîne	N/A
	alwaysCreateNewEnt reprise	Booléen	N/A
	internalUpdatedAt	Long	N/A
	businessUnitId	Entier	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Clé portable	Chaîne	N/A
	paymentSessionTemp latelIdentifiants	Liste	N/A
	selectedExternalOp tions	Liste	N/A

HubSpot API v1 :

Entité	Champ	Type de données	Opérateurs pris en charge
Campagne	id	Entier	N/A
	appld	Entier	N/A
	Nom de l'application	Chaîne	N/A
	lastUpdatedTime	Long	N/A
List_Contacts	dynamic	Booléen	N/A
	name	Chaîne	N/A
	ID du portail	Entier	N/A
	createdAt	Long	N/A
	listId	Entier	N/A
	updatedAt	Long	N/A
	ListType	Chaîne	N/A
	filtres	Liste	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Identifiant de l'auteur	Entier	N/A
	Métadonnées	Struct	N/A
	archived	Booléen	N/A
	ilsFilterBranch	Chaîne	N/A
	Identifiants de filtre	Liste	N/A
	Limite exemptée	Booléen	N/A
	interne	Booléen	N/A
	readOnly	Booléen	N/A
	Identifiant du parent	Entier	N/A
Événement_e-mail	id	Chaîne	N/A
	type	Chaîne	N/A
	destinataire	Chaîne	N/A
	ID du portail	Entier	N/A
	appld	Entier	N/A
	Nom de l'application	Chaîne	N/A
	emailCampaignId	Long	N/A
	tentative	Entier	N/A
	créé	Long	N/A
	Envoyé par	Struct	N/A
	ID SMT	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	réponse	Chaîne	N/A
	subject	Chaîne	N/A
	cc	Liste	N/A
	bcc	Liste	N/A
	Répondre à	Liste	N/A
	from	Chaîne	N/A
	Raison de la chute	Chaîne	N/A
	Supprimer un message	Chaîne	N/A
	navigateur	Struct	N/A
	userAgent	Chaîne	N/A
	duration	Long	N/A
	location	Struct	N/A
	Événement filtré	Booléen	N/A
	Type d'appareil	Chaîne	N/A
	Raison supprimée	Chaîne	N/A
	Message supprimé	Chaîne	N/A
CRM Pipeline	pipelineId	Chaîne	N/A
	createdAt	Long	N/A
	updatedAt	Long	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	objectType	Chaîne	N/A
	étiquette	Chaîne	N/A
	Afficher la commande	Entier	N/A
	actif	Booléen	N/A
	étapes	Liste	N/A
	objectTypeld	Chaîne	N/A
	default	Booléen	N/A

Requêtes de partitionnement

Vous pouvez fournir les options supplémentaires de Spark

PARTITION_FIELD, LOWER_BOUND, UPPER_BOUND, et NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- PARTITION_FIELD: le nom du champ à utiliser pour partitionner la requête.
- LOWER_BOUND: une valeur inférieure inclusive du champ de partition choisi.

Pour le DateTime champ, nous acceptons la valeur au format ISO.

Exemples de valeurs valides :

```
"2024-01-01T10:00:00.115Z"
```

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: le nombre de partitions.

Le tableau suivant décrit les détails relatifs à la prise en charge des champs de partitionnement des entités :

Nom de l'entité	Champs de partitionnement	Type de données
contact	hs_object_id	Long
	date de création, date de dernière modification	DateTime
company	hs_object_id	Long
	date de création, date de dernière modification hs_	DateTime
vente	hs_object_id	Long
	date de création, hs_date de création, date de dernière modification	DateTime
ticket	hs_object_id	Long
	date de création, date de dernière modification hs_	DateTime
produit	hs_object_id	Long
	date de création, date de dernière modification hs_	DateTime
objet_personnalisé	hs_object_id	Long
	date de création, date de dernière modification hs_	DateTime
appel	hs_object_id	Long
	date de création, date de dernière modification hs_	DateTime
e-mail	hs_object_id	Long

Nom de l'entité	Champs de partitionnement	Type de données
réunion	date de création, date de dernière modification hs_	DateTime
	hs_object_id	Long
note	date de création, date de dernière modification hs_	DateTime
	hs_object_id	Long
tâche	date de création, date de dernière modification hs_	DateTime
	hs_object_id	Long
courriel_postale	date de création, date de dernière modification hs_	DateTime
	hs_object_id	Long

Exemple :

```

hubspot_read = glueContext.create_dynamic_frame.from_options(
    connection_type="hubspot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "company",
        "API_VERSION": "v3",
        "PARTITION_FIELD": "hs_object_id"
        "LOWER_BOUND": "50"
        "UPPER_BOUND": "16726619290"
        "NUM_PARTITIONS": "10"
    }

```

HubSpot options de connexion

Les options de connexion suivantes sont disponibles pour HubSpot :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans HubSpot.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. HubSpot Version de l'API Rest que vous souhaitez utiliser. Par exemple : v1, v2, v3, v4.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.
- **TRANSFER_MODE**(String) - Utilisé pour indiquer si la requête doit être exécutée en mode asynchrone.

Limitations et remarques relatives au HubSpot connecteur

Les limitations ou remarques suivantes concernent le HubSpot connecteur :

- Les points de terminaison de recherche sont limités à 10 000 résultats au total pour une requête donnée. Toute partition contenant plus de 10 000 enregistrements provoquera une erreur 400.
- Les autres limitations importantes du connecteur sont décrites dans la section [Limitations](#).
- Un maximum de trois instructions de filtrage sont acceptées par HubSpot.
- Actuellement, HubSpot prend en charge les associations entre HubSpot des objets standard (par exemple, contact, entreprise, offre ou ticket) et des objets personnalisés.
 - Pour un compte gratuit : vous ne pouvez créer que 10 types d'association entre chaque paire d'objets (par exemple, contacts et entreprises).

- Pour un compte Super Admin : vous ne pouvez créer que 50 types d'association au maximum entre chaque paire d'objets.
- Pour plus d'informations, consultez [Associations v4](#) et [Création et utilisation d'étiquettes d'association](#).
- Les objets « Quote » et « Communications » ne sont pas présents pour les associations car ils ne sont actuellement pas pris en charge dans le connecteur.
- Pour Async, le SaaS trie les valeurs par ordre croissant uniquement.
- Pour l'EntitéTicket, le SaaS ne renvoie pas le `hs_object_id` champ en mode asynchrone.

Connexion aux publicités Instagram

Instagram est une application populaire de partage de photos qui vous permet d'entrer en contact avec des marques, des célébrités, des leaders d'opinion, des amis, des membres de votre famille, etc. Il s'agit d'un service de partage de photos et de réseaux sociaux. Les utilisateurs peuvent prendre des photos ou de courtes vidéos et les partager avec leurs abonnés. Les publicités Instagram sont des publications pour lesquelles les entreprises peuvent payer pour être diffusées aux utilisateurs d'Instagram.

Rubriques

- [AWS Glue support pour Instagram Ads](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration des publicités Instagram](#)
- [Configuration des connexions Instagram Ads](#)
- [Lecture depuis les entités Instagram Ads](#)
- [Options de connexion à Instagram Ads](#)
- [Limitations et remarques relatives au connecteur Instagram Ads](#)

AWS Glue support pour Instagram Ads

AWS Glue prend en charge les publicités Instagram comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données d'Instagram Ads.

Soutenu en tant que cible ?

Non

Versions de l'API Instagram Ads prises en charge

Les versions suivantes de l'API Instagram Ads sont prises en charge :

- v17.0
- version 18.0
- version 19.0
- version 20.0

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM,

CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration des publicités Instagram

Avant de pouvoir AWS Glue transférer des données depuis Instagram Ads, vous devez remplir les conditions suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Les comptes Instagram Standard sont accessibles indirectement via Facebook.
- L'authentification de l'utilisateur est nécessaire pour générer le jeton d'accès.
- Le connecteur du SDK Instagram Ads implémentera le OAuth flux de jetons d'accès utilisateur.
- Nous utilisons OAuth2 .0 pour authentifier nos demandes d'API auprès d'Instagram Ads. Cette authentification basée sur le Web s'inscrit dans le cadre de l'architecture Multi-Factor Authentication (MFA), qui est un sur-ensemble de la 2FA.
- L'utilisateur doit accorder des autorisations pour accéder aux points de terminaison. Pour accéder aux données de l'utilisateur, l'autorisation du point de terminaison est gérée par le biais [d'autorisations](#) et de [fonctionnalités](#).

Obtenir des informations d'identification OAuth 2.0

Pour obtenir des informations d'identification d'API afin de pouvoir effectuer des appels authentifiés vers votre instance, consultez [Graph API](#).

Configuration des connexions Instagram Ads

Instagram Ads prend en charge le type de subvention AUTHORIZATION_CODE pour. OAuth2

- Ce type de subvention est considéré comme tridimensionnel OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console.
- Les utilisateurs peuvent choisir de créer leur propre application connectée dans Instagram Ads et de fournir leur propre identifiant client et leur secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Instagram Ads pour se connecter et autoriser AWS Glue l'accès à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'accès. Un jeton d'utilisateur système expirant est valide pendant 60 jours à compter de la date de génération ou d'actualisation. Pour assurer la continuité, le développeur doit actualiser le jeton d'accès dans les 60 jours. Ne pas le faire entraîne la perte du jeton d'accès et oblige le développeur à en obtenir un nouveau pour retrouver l'accès à l'API. Voir [Actualiser le jeton d'accès](#).

Pour configurer une connexion à Instagram Ads, procédez comme suit :

1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Instagram Ads.
 - b. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires à cet effet :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- c. Fournissez l'ID client de l'application client gérée par l'utilisateur.
 - d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons. Le secret sélectionné doit comporter une clé `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` dont la valeur est le secret client de l'application connectée.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture depuis les entités Instagram Ads

Prérequis

Un objet Instagram Ads dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet. Les tableaux suivants indiquent les entités prises en charge.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Campagne	Oui	Oui	Non	Oui	Oui
Set de publicités	Oui	Oui	Non	Oui	Oui
Publicités	Oui	Oui	Non	Oui	Oui
Créatif publicitaire	Non	Oui	Non	Oui	Non
Insights - Compte	Non	Oui	Non	Oui	Non
Image publicitaire	Oui	Oui	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Insights - Publicité	Oui	Oui	Non	Oui	Oui
Perspectives - AdSet	Oui	Oui	Non	Oui	Oui
Insights - Campagne	Oui	Oui	Non	Oui	Oui

Exemple :

```
instagramAds_read = glueContext.create_dynamic_frame.from_options(
    connection_type="instagramads",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v20.0"
    }
)
```

Détails de l'entité et du champ Instagram Ads

Pour plus d'informations sur les entités et les détails des champs, voir :

- [Campagne](#)
- [Set de publicités](#)
- [Annonce](#)
- [Créatif publicitaire](#)
- [Aperçu des comptes publicitaires](#)
- [Image publicitaire](#)
- [Informations sur les publicités](#)
- [AdSets Perspectives](#)
- [Informations sur les campagnes](#)

Pour plus d'informations, consultez la section [API marketing](#).

 Note

Les types de données Struct et List sont convertis en type de données String en réponse aux connecteurs.

Requêtes de partitionnement

Vous pouvez fournir les options supplémentaires de Spark

PARTITION_FIELD, LOWER_BOUND, UPPER_BOUND, et NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- PARTITION_FIELD: le nom du champ à utiliser pour partitionner la requête.
- LOWER_BOUND: une valeur inférieure inclusive du champ de partition choisi.

Pour le DateTime champ, nous acceptons le format d'horodatage Spark utilisé dans les requêtes SQL Spark.

Exemple de valeur valide :

```
"2022-01-01T00:00:00.000Z"
```

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.

Exemple de valeur valide :

```
"2024-01-02T00:00:00.000Z"
```

- NUM_PARTITIONS: le nombre de partitions.

Exemple :

```
instagramADs_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="instagramads",  
    connection_options={
```

```
"connectionName": "connectionName",
"ENTITY_NAME": "entityName",
"API_VERSION": "v20.0",
"PARTITION_FIELD": "created_time"
"LOWER_BOUND": "2022-01-01T00:00:00.000Z"
"UPPER_BOUND": "2024-01-02T00:00:00.000Z"
"NUM_PARTITIONS": "10"
}
```

Options de connexion à Instagram Ads

Les options de connexion pour les publicités Instagram sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Instagram Ads.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Instagram Ads Graph que vous souhaitez utiliser. Par exemple : v21.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour lire. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour lire. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour lire. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour lire. Nombre de partitions à lire.

Limitations et remarques relatives au connecteur Instagram Ads

Voici les limites ou remarques relatives au connecteur Instagram Ads :

- Le nombre d'appels d'une application est le nombre d'appels qu'un utilisateur peut passer pendant une période d'une heure continue (200 fois par le nombre d'utilisateurs). Pour plus de détails sur les limites de [taux, consultez les sections Limites de taux](#) et Limites de [taux pour les cas d'utilisation professionnelle](#).

Connexion à Intercom in AWS Glue Studio

Intercom est l'Engagement OS, un canal ouvert entre votre entreprise et vos clients, sur le plan du produit, sur le moment et selon leurs conditions, créant un dialogue permanent qui vous permet de tirer le meilleur parti de chaque engagement tout au long du parcours client.

Rubriques

- [AWS Glue support pour Intercom](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de l'interphone](#)
- [Configuration des connexions d'interphone](#)
- [Lecture depuis les entités Intercom](#)
- [Options de connexion par interphone](#)
- [Limites](#)
- [Création d'un nouveau compte Intercom et configuration de l'application client](#)

AWS Glue support pour Intercom

AWS Glue prend en charge Intercom comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données d'Intercom.

Soutenu en tant que cible ?

Non

Versions d'API Intercom prises en charge

v2,5. Pour la prise en charge des entités par version spécifique, voir [Lecture depuis les entités Intercom](#).

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Vous pouvez également utiliser les politiques IAM gérées suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM et Amazon EC2. Amazon CloudWatch Logs Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de l'interphone

Avant de pouvoir AWS Glue effectuer un transfert depuis Intercom, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous avez un compte Intercom. Pour de plus amples informations, veuillez consulter [Création d'un nouveau compte Intercom et configuration de l'application client](#).

- Votre compte Intercom est activé pour accéder à l'API.
- Vous devez disposer d'une application sous le compte développeur Intercom qui fournit les informations d'identification du client qui permettent AWS Glue d'accéder à vos données en toute sécurité lorsqu'il passe des appels authentifiés vers votre compte. Pour plus d'informations, consultez Intercom - Étapes de création d'un nouveau compte et d'une application client.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Intercom.

Configuration des connexions d'interphone

Intercom prend en charge le type de `AUTHORIZATION_CODE` subvention pour OAuth 2.

Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. La AWS Glue console redirigera l'utilisateur vers Google Ads, où il devra se connecter et accorder AWS Glue les autorisations demandées pour accéder à son instance d'intercom.

Les utilisateurs doivent fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Intercom pour se connecter et autoriser l'accès AWS Glue à leurs ressources.

Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.

Pour plus d'informations sur la création d'une application connectée pour le OAuth flux de code d'autorisation, consultez la section [API des annonces](#).

Pour configurer une connexion Intercom :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes. Il est nécessaire de créer un secret pour chaque connexion dans AWS Glue.
 - a. Pour les applications connectées gérées par le client, Secret doit contenir le jeton d'accès à l'application connectée, le jeton d'actualisation, le client_id et le client_secret.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :

- a. Lorsque vous sélectionnez un type de connexion, sélectionnez Intercom.
- b. Fournissez l'environnement d'interphone.
- c. Sélectionnez le rôle IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture depuis les entités Intercom

Prérequis

- Un objet Intercom dont vous souhaitez lire un extrait. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

Entité	API_Vversion 1	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Admins	v2,5	Non	Non	Non	Oui	Non
Les entreprises	v2,5	Non	Oui	Non	Oui	Non
Conversations	v2,5	Oui	Oui	Oui	Oui	Oui
Attributs des données	v2,5	Non	Non	Non	Oui	Non
Contacts	v2,5	Oui	Oui	Oui	Oui	Oui
Segments	v2,5	Non	Non	Non	Oui	Non
Balises	v2,5	Non	Non	Non	Oui	Non
Equipes	v2,5	Non	Non	Non	Oui	Non

Exemple

```
Intercom_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Intercom",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "company",
        "API_VERSION": "V2.5"
    }
)
```

Détails de l'entité et du champ d'interphone

Entité	Champ	Type de données	Opérateurs pris en charge
Admins	type	Chaîne	NA
Admins	id	Chaîne	NA
Admins	avatar	Struct	NA
Admins	name	Chaîne	NA
Admins	e-mail	Chaîne	NA
Admins	Away_Mode_Activé	Booléen	NA
Admins	away_mode_réassigner	Booléen	NA
Admins	has_inbox_seat	Booléen	NA
Admins	teams_ids	Liste	NA
Admins	titre_poste	Chaîne	NA
Les entreprises	type	Chaîne	NA
Les entreprises	id	Chaîne	NA
Les entreprises	app_id	Chaîne	NA
Les entreprises	created_at	DateTime	NA
Les entreprises	remote_created_at	DateTime	NA
Les entreprises	updated_at	DateTime	NA
Les entreprises	dernière_demande_at	DateTime	NA
Les entreprises	plan	Struct	NA
Les entreprises	identifiant_entreprise	Chaîne	NA

Entité	Champ	Type de données	Opérateurs pris en charge
Les entreprises	name	Chaîne	NA
Les entreprises	attributs_personnalisés	Struct	NA
Les entreprises	décompte des sessions	Entier	NA
Les entreprises	dépenses_mensuelles	Entier	NA
Les entreprises	nombre d'utilisateurs	Entier	NA
Les entreprises	industrie	Chaîne	NA
Les entreprises	size	Entier	NA
Les entreprises	website	Chaîne	NA
Les entreprises	balises	Struct	NA
Les entreprises	segments	Struct	NA
Contacts	id	Chaîne	EQUAL_TO. NOT_EQUAL_TO
Contacts	type	Chaîne	NA
Contacts	identifiant de l'espace de travail	Chaîne	NA
Contacts	external_id	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	rôle	Chaîne	EQUAL_TO. NOT_EQUAL_TO

Entité	Champ	Type de données	Opérateurs pris en charge
Contacts	e-mail	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	phone	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	name	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	avatar	Chaîne	NA
Contacts	owner_id	Entier	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Contacts	profils_sociaux	Struct	NA
Contacts	has_hard_bounced	Booléen	EQUAL_TO
Contacts	mail_e-mail marqué comme spam	Booléen	EQUAL_TO
Contacts	désabonné_de_e-mails	Booléen	EQUAL_TO
Contacts	created_at	DateTime	ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Contacts	updated_at	DateTime	ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À

Entité	Champ	Type de données	Opérateurs pris en charge
Contacts	inscrip_at	DateTime	ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Contacts	vu pour la dernière_à	DateTime	ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Contacts	last_replied_at	DateTime	ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Contacts	dernier_contacté_at	DateTime	ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Contacts	last_email_opened_at	DateTime	ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Contacts	last_email_clicked_at	DateTime	ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Contacts	language_override	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	navigateur	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	version du navigateur	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO

Entité	Champ	Type de données	Opérateurs pris en charge
Contacts	langue_navigateur	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	os	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	location	Struct	NA
Contacts	location_pays	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	location_région	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	location_ville	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	nom_application_android	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	version de l'application Android	Chaîne	NA
Contacts	appareil_Android	Chaîne	NA
Contacts	version du système d'exploitation Android	Chaîne	NA

Entité	Champ	Type de données	Opérateurs pris en charge
Contacts	version du SDK Android	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	android_last_seen_at	Date	NA
Contacts	nom_app_ios	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	Version de l'application iOS	Chaîne	NA
Contacts	appareil_ios	Chaîne	NA
Contacts	Version iOS	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	Version du SDK iOS	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Contacts	ios_last_seen_at	DateTime	NA
Contacts	attributs_personnalisés	Struct	NA
Contacts	balises	Struct	NA
Contacts	notes	Struct	NA
Contacts	entreprises	Struct	NA
Contacts	désabonné_de_sms	Booléen	NA

Entité	Champ	Type de données	Opérateurs pris en charge
Contacts	consentement par SMS	Booléen	NA
Contacts	types_d'abonnement opté_refusés	Struct	NA
Contacts	référent	Chaîne	NA
Contacts	campagne utm_	Chaîne	NA
Contacts	utm_content	Chaîne	NA
Contacts	utm_medium	Chaîne	NA
Contacts	utm_source	Chaîne	NA
Contacts	utm_term	Chaîne	NA
Conversations	type	Chaîne	NA
Conversations	id	Entier	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	created_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	updated_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	source	Struct	NA
Conversations	identifiant_source	Chaîne	ÉGAL À, PAS ÉGAL À

Entité	Champ	Type de données	Opérateurs pris en charge
Conversations	source_type	Chaîne	ÉGAL À, PAS ÉGAL À,
Conversations	source_livré_sous forme	Chaîne	EQUAL_TO, NOT_EQUAL_TO,
Conversations	sujet_source	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	source_body	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	ID de l'auteur_source	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	type_auteur_source	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	nom_auteur_source	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	courriel_auteur_source	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	URL de la source	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	contacts	Struct	NA

Entité	Champ	Type de données	Opérateurs pris en charge
Conversations	coéquipiers	Struct	NA
Conversations	title	Chaîne	NA
Conversations	admin_assigne_id	Entier	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	identifiant du responsable de l'équipe	Entier	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	attributs_personnalisés	Struct	NA
Conversations	ouvrir	Booléen	EQUAL_TO
Conversations	state	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	lire	Booléen	EQUAL_TO
Conversations	en attente depuis	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	snoozed_until	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	balises	Struct	NA
Conversations	réponse_premier contact	Struct	NA

Entité	Champ	Type de données	Opérateurs pris en charge
Conversations	priority	Chaîne	ÉGAL À, PAS ÉGAL À
Conversations	topics	Struct	NA
Conversations	sla_appliqué	Struct	NA
Conversations	évaluation_conversation	Struct	NA
Conversations	conversation_rating_requested_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	conversation_rating_replied_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	score d'évaluation de la conversation	Entier	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	remarque d'évaluation de la conversation	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	conversation_rating_contact_id	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	conversation_rating_admin_id	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	statistics	Struct	NA

Entité	Champ	Type de données	Opérateurs pris en charge
Conversations	statistiques_time_to_assignment	Entier	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistiques_time_to_admin_reply	Entier	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistiques_time_to_first_close	Entier	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistiques_time_to_last_close	Entier	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistiques_median_time_to_reply	Entier	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistics_first_contact_reply_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistics_first_assignment_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistics_first_admin_reply_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistics_first_close_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À

Entité	Champ	Type de données	Opérateurs pris en charge
Conversations	statistics_last_as signment_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistics_last_as signment_admin_reply_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistics_last_contact_reply_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistics_last_admin_reply_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistiques_last_close_at	DateTime	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistiques_last_closed_by_id	Chaîne	CONTIENT, EQUAL_TO, NOT_EQUAL_TO
Conversations	statistics_count_reopens	Entier	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistiques_nombre_assignations	Entier	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À
Conversations	statistiques_count_conversation_parts	Entier	ÉGAL À, NON ÉGAL À, SUPÉRIEUR À, INFÉRIEUR À

Entité	Champ	Type de données	Opérateurs pris en charge
Conversations	parties de conversation	Liste	NA
Attributs des données	id	Entier	NA
Attributs des données	type	Chaîne	NA
Attributs des données	modèle	Chaîne	NA
Attributs des données	name	Chaîne	NA
Attributs des données	nom_complet	Chaîne	NA
Attributs des données	étiquette	Chaîne	NA
Attributs des données	description	Chaîne	NA
Attributs des données	data_type	Chaîne	NA
Attributs des données	options	Liste	NA
Attributs des données	API_Writable	Booléen	NA
Attributs des données	UI_Writable	Booléen	NA
Attributs des données	personnalisé	Booléen	NA
Attributs des données	archived	Booléen	NA
Attributs des données	created_at	Booléen	NA
Attributs des données	updated_at	DateTime	NA
Attributs des données	admin_id	Chaîne	NA
Segments	type	Chaîne	NA
Segments	id	Chaîne	NA

Entité	Champ	Type de données	Opérateurs pris en charge
Segments	name	Chaîne	NA
Segments	created_at	DateTime	NA
Segments	updated_at	DateTime	NA
Segments	type_personne	Chaîne	NA
Segments	count	Entier	NA
Balises	type	Chaîne	NA
Balises	id	Chaîne	NA
Balises	name	Chaîne	NA
Equipes	type	Chaîne	NA
Equipes	id	Chaîne	NA
Equipes	name	Chaîne	NA
Equipes	identifiant_administrateurs	Liste	NA

Requêtes de partitionnement

Des options Spark supplémentaires `PARTITION_FIELD_LOWER_BOUND`, `UPPER_BOUND`, `NUM_PARTITIONS` peuvent être fournies si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur inférieure inclusive du champ de partition choisi.

Pour la date, nous acceptons le format de date Spark utilisé dans les requêtes SQL Spark.
Exemple de valeurs valides : "2024-02-06".

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: nombre de partitions.

Les détails relatifs à la prise en charge des champs de partitionnement par entité sont présentés dans le tableau suivant.

Nom de l'entité	Champ de partitionnement	Type de données
Contacts	created_at, updated_at, last_seen_at	DateTime
Conversations	id	Entier
Conversations	created_at, updated_at	DateTime

Exemple

```
Intercom_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="Intercom",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "conversation",  
        "API_VERSION": "V2.5",  
        "PARTITION_FIELD": "created_at"  
        "LOWER_BOUND": "2022-07-13T07:55:27.065Z"  
        "UPPER_BOUND": "2022-08-12T07:55:27.065Z"  
        "NUM_PARTITIONS": "2"  
    }  
)
```

Options de connexion par interphone

Les options de connexion pour Intercom sont les suivantes :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Intercom.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Intercom Rest que vous souhaitez utiliser. Exemple : v2.5.

- `SELECTED_FIELDS(Liste<String>)` - Par défaut : vide (`SELECT *`). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- `FILTER_PREDICATE(String)` - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- `QUERY(String)` - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- `PARTITION_FIELD(String)` - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- `LOWER_BOUND(String)` - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- `UPPER_BOUND(String)` - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS(Entier)` - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.
- `INSTANCE_URL(String)` - URL de l'instance sur laquelle l'utilisateur souhaite exécuter les opérations. Par exemple : <https://api.intercom.io>.

Limites

Les limites du connecteur Intercom sont les suivantes :

- Lorsque vous utilisez l'entité Entreprise, il existe une limite de 10 000 entreprises pouvant être retournées. Pour plus d'informations, consultez [l'API Lister toutes les entreprises](#).
- Lors de l'application du tri par, le filtre est obligatoire pour les entités Contact et Conversation.
- Le MCA est pris en charge par le fournisseur de SaaS. Cependant, sur la base des limites de débit des API mentionnées dans la documentation, nous n'hébergerons pas MCA sur d'autres charges de travail AWS Glue car cela pourrait avoir un impact sur d'autres charges de travail et entraîner des problèmes de performances en raison de la contention des ressources.

Création d'un nouveau compte Intercom et configuration de l'application client

Création d'un compte Intercom

1. Choisissez [l'URL de l'intercom](#) et choisissez Commencer mon essai gratuit dans le coin supérieur droit de la page.
2. Cliquez sur le bouton Essayer gratuitement dans le coin supérieur droit de la page.
3. Choisissez le type d'entreprise dont vous avez besoin.

4. Entrez toutes les informations requises sur la page.
5. Après avoir saisi toutes les informations, choisissez Enregistrer.

Création d'une application pour développeurs Intercom

Pour obtenir l'ID client et le secret du client, vous devez créer un compte développeur.

1. Accédez à <https://app.intercom.com/>.
2. Entrez l'adresse e-mail et le mot de passe/connectez-vous à l'aide de Google et connectez-vous.
3. Choisissez le profil utilisateur dans le coin inférieur gauche et choisissez les paramètres.
4. Choisissez Applications et intégration.
5. Choisissez l'onglet Developer Hub sous Applications et intégration.
6. Choisissez Nouvelle application et créez l'application ici.
7. Indiquez le nom de l'application et choisissez Create app.
8. Dans l'application, accédez à la section Authentification.
9. Choisissez l'édition et ajoutez une redirection URIs. Ajoutez l'URL de redirection spécifique à votre région en tant que `https://<aws-region>.console.aws.amazon.com/gluestudio/oauth` Par exemple, ajoutez `https://us-east-1.console.aws.amazon.com/gluestudio/oauth` for the us-east-1 region.
10. Obtenez l'ID client et le secret client générés dans la section Informations de base.

Connexion à Jira Cloud

Jira Cloud est une plateforme développée par Atlassian. La plateforme inclut des produits de suivi des problèmes qui aident les équipes à planifier et à suivre leurs projets Agile. En tant qu'utilisateur de Jira Cloud, votre compte contient des données relatives à vos projets, telles que les problèmes, les flux de travail et les événements. Vous pouvez l'utiliser AWS Glue pour transférer vos données Jira Cloud vers certains AWS services ou d'autres applications compatibles.

Rubriques

- [AWS Glue support pour Jira Cloud](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Jira Cloud](#)

- [Configuration des connexions Jira Cloud](#)
- [Lecture depuis les entités Jira Cloud](#)
- [Options de connexion Jira Cloud](#)
- [Limitations et remarques relatives au connecteur Jira Cloud](#)

AWS Glue support pour Jira Cloud

AWS Glue prend en charge Jira Cloud comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données depuis Jira Cloud.

Soutenu en tant que cible ?

Non

Versions de l'API Jira Cloud prises en charge

Les versions suivantes de l'API Jira Cloud sont prises en charge :

- v2

Pour la prise en charge des entités par version spécifique, voir Entités prises en charge pour la source.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
```

```
        "glue:DescribeEntity"  
      ],  
      "Resource": "*"   
    }  
  ]  
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Jira Cloud

Avant de pouvoir AWS Glue transférer des données depuis Jira Cloud vers des destinations prises en charge, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous disposez d'un compte Atlassian sur lequel vous pouvez utiliser le produit logiciel Jira dans Jira Cloud. Pour de plus amples informations, veuillez consulter [Création d'un compte Jira Cloud](#).
- Vous devez avoir créé un AWS compte avec l'accès au service à AWS Glue.
- Cette application fournit les informations d'identification du client qui AWS Glue permettent d'accéder à vos données en toute sécurité lorsqu'elle passe des appels authentifiés vers votre compte. Pour plus d'informations, consultez [Enabling OAuth 2.0 \(3LO\)](#) dans la documentation Atlassian Developer.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Jira Cloud.

Création d'un compte Jira Cloud

Pour créer un compte Jira Cloud, procédez comme suit :

1. Accédez à l'URL [d'inscription Atlassian](#).
2. Entrez votre adresse e-mail professionnelle et votre nom, puis cliquez sur Accepter. Vous recevez un e-mail de vérification.
3. Après avoir vérifié votre adresse e-mail, vous pouvez créer un mot de passe et choisir S'inscrire.
4. Entrez le nom et le mot de passe, puis choisissez S'inscrire.
5. Vous êtes redirigé vers une page où vous devez accéder à votre site. Entrez le nom du site et choisissez Accepter.

Une fois votre site Atlassian Cloud démarré, vous pouvez configurer votre Jira en répondant à quelques questions selon vos préférences en matière de type de projet.

Pour vous connecter à un compte existant :

1. Accédez à l'[URL de connexion Atlassian](#) et entrez vos informations d'identification.
2. Entrez votre e-mail et votre mot de passe, puis cliquez sur Se connecter. Vous êtes redirigé vers le tableau de bord Jira.

Création d'une application dans votre Jira Cloud

Pour créer une application dans Jira Cloud et obtenir l'ID client et le secret du client auprès de l'application client gérée, procédez comme suit :

1. Accédez à l'[URL de Jira Cloud](#) et saisissez les informations d'identification.
2. Choisissez Create et sélectionnez l'option d'intégration OAuth 2.0.
3. Entrez le nom de l'application, vérifiez les conditions générales et choisissez Créer.
4. Accédez à la section Distribution dans le menu de gauche et choisissez Modifier.
5. Dans la section Modifier les contrôles de distribution :
 - a. Sélectionnez ÉTAT DE DISTRIBUTION comme Partage.
 - b. Entrez le nom du fournisseur.

- c. Entrez l'URL de votre politique de confidentialité. Par exemple, <https://docs.aws.amazon.com/glue/latest/dg/security-iam-awsmanpol.html>
 - d. Entrez l'URL de vos conditions d'utilisation (facultatif).
 - e. Entrez l'URL de votre contact du service client (facultatif).
 - f. Sélectionnez Oui/Non dans la DÉCLARATION DE DONNÉES PERSONNELLES et choisissez Enregistrer les modifications.
6. Accédez à Autorisations dans le menu de gauche de l'application correspondante.
 7. Pour l'API Jira, choisissez Ajouter. Une fois ajoutée, choisissez l'option Configuration.
 8. Dans la section Étendue classique > API REST de la plateforme Jira, choisissez Modifier les étendues... et cochez toutes les étendues. Cliquez sur Sauvegarder
 9. Sous Étendue granulaire, choisissez Modifier les étendues, puis sélectionnez les étendues suivantes :
- 10 Faites défiler la page vers le bas et trouvez des scopes. Il existe deux types de champs d'application que vous devez sélectionner sous les rubriques « CRM » et « Standard ».
 - 11 Ajoutez les étendues suivantes :

```
read:application-role:jira
read:audit-log:jira
read:avatar:jira
read:field:jira
read:group:jira
read:instance-configuration:jira
read:issue-details:jira
read:issue-event:jira
read:issue-link-type:jira
read:issue-meta:jira
read:issue-security-level:jira
read:issue-security-scheme:jira
read:issue-type-scheme:jira
read:issue-type-screen-scheme:jira
read:issue-type:jira
read:issue.time-tracking:jira
read:label:jira
read:notification-scheme:jira
read:permission:jira
read:priority:jira
read:project:jira
read:project-category:jira
```

```
read:project-role:jira
read:project-type:jira
read:project-version:jira
read:project.component:jira
read:project.property:jira
read:resolution:jira
read:screen:jira
read:status:jira
read:user:jira
read:workflow-scheme:jira
read:workflow:jira
read:field-configuration:jira
read:issue-type-hierarchy:jira
read:webhook:jira
```

12 Accédez à Authentification dans le menu de gauche, puis choisissez Ajouter.

13 Entrez une URL de rappel telle que oauth <https://us-east-1.console.aws.amazon.com/gluestudio/>

14 Accédez à Paramètres dans le menu de gauche et faites défiler la page vers le bas pour les détails de l'authentification. Notez l'ID client et le secret.

Configuration des connexions Jira Cloud

Jira Cloud prend en charge le type de subvention `AUTHORIZATION_CODE` pour OAuth2

- Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers un serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. La AWS Glue console redirige l'utilisateur vers Jira Cloud où il doit se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Jira Cloud.
- Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans Jira Cloud et de fournir leur propre identifiant client et leur secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Jira Cloud pour se connecter et autoriser l'accès AWS Glue à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- Pour consulter la documentation publique de Jira Cloud sur la création d'une application connectée pour le OAuth flux de code d'autorisation, consultez [Enabling OAuth 2.0 \(3LO\)](#).

Pour configurer une connexion Jira Cloud :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir le secret du consommateur de l'application connectée avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
 - b. Remarque : Vous devez créer un secret pour la connexion dans AWS Glue.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Jira Cloud.
 - b. Fournissez l'environnement Jira Cloud.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture depuis les entités Jira Cloud

Prérequis

Un objet Jira Cloud dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet, tel que Audit Record ou Issue. Le tableau suivant indique les entités prises en charge.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Compte rendu d'audit	Oui	Oui	Non	Oui	Oui
Problème	Oui	Oui	Non	Oui	Oui
Champ du problème	Non	Non	Non	Oui	Non
Configuration du champ de problème	Oui	Oui	Non	Oui	Oui
Type de lien vers le problème	Non	Non	Non	Oui	Non
Schéma de notification des problèmes	Oui	Oui	Non	Oui	Oui
Schéma de sécurité des problèmes	Non	Non	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Schéma des types de problèmes	Oui	Oui	Oui	Oui	Oui
Schéma d'écran des types de problèmes	Oui	Oui	Oui	Oui	Oui
Type de problème	Non	Non	Non	Oui	Non
Réglage Jira	Oui	Non	Non	Oui	Non
Configuration avancée de Jira	Non	Non	Non	Oui	Non
Configuration globale de Jira	Non	Non	Non	Oui	Non
Étiquette	Non	Non	Non	Oui	Oui
Moi-même	Oui	Non	Non	Oui	Non
Autorisations	Non	Non	Non	Oui	Non
Projet	Oui	Oui	Oui	Oui	Oui
Catégorie de projet	Non	Non	Non	Oui	Non
Type de projet	Non	Non	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Informations sur le serveur	Non	Non	Non	Oui	Non
Users	Non	Non	Non	Oui	Non
Flux de travail	Oui	Oui	Oui	Oui	Oui
Schéma de workflow	Non	Oui	Non	Oui	Oui
Association de projets de schéma de flux de travail	Oui	Non	Non	Oui	Non
État du flux de travail	Non	Non	Non	Oui	Non
Catégorie d'état du flux de travail	Non	Non	Non	Oui	Non

Exemple :

```
jiracloud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="JiraCloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "audit-record",
        "API_VERSION": "v2"
    }
)
```

Détails de l'entité et du champ Jira Cloud :

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
Compte rendu d'audit	filtre	Chaîne	"="
	from	DateTime	"="
	to	DateTime	"="
	id	Entier	N/A
	récapitulatif	Chaîne	N/A
	Adresse distante	Chaîne	N/A
	authorAccountId	Chaîne	N/A
	créé	Chaîne	N/A
	category	Chaîne	N/A
	eventSource	Chaîne	N/A
	description	Chaîne	N/A
	Objet : article	Struct	N/A
	Valeurs modifiées	Liste	N/A
	Objets associés	Liste	N/A
Groups	groupName	Liste	"="
	name	Chaîne	N/A
	groupId	Chaîne	"="
Problème	Version affectée	Chaîne	"=, !="
	cessionnaire	Chaîne	"=, !="
	category	Chaîne	"=, !="

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	composant	Chaîne	"=", "!="
	créateur	Chaîne	"=", "!="
	en raison	DateTime	N/A
	epic_link	Chaîne	"=", "!="
	filtre	Chaîne	"=", "!="
	Version fixe	Chaîne	"=", "!="
	Niveau hiérarchique	Entier	"=", "!="
	Clé du problème	Chaîne	"=", "!=, >, <, >=, <="
	Lien vers le problème	Chaîne	"=", "!="
	issueLinkType	Chaîne	"=", "!="
	labels	Chaîne	"=", "!="
	Vu pour la dernière fois	DateTime	« =, >, <, >=, <=, entre »
	level	Chaîne	"=", "!="
	parent	Chaîne	"=", "!="
	priority	Chaîne	"=", "!="
	project	Chaîne	"=", "!="
	Type de projet	Chaîne	"=", "!="
	journaliste	Chaîne	"=", "!="
	resolution	Chaîne	"=", "!="

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	résolus	DateTime	« =, >, <, >=, <=, entre »
	sprint	Chaîne	"=, !="
	status	Chaîne	"=, !="
	type	Chaîne	"=, !="
	updated	DateTime	« =, >, <, >=, <=, entre »
	électeur	Chaîne	"=, !="
	votes	Entier	« =, !=, <, >, <=, >=, entre »
	observateur	Chaîne	"=, !="
	les observateurs	Entier	« =, !=, <, >, <=, >=, entre »
	Ratio de travail	Entier	« =, !=, <, >, <=, >=, entre »
	Valider la requête	Chaîne	"="
	développer	Chaîne	"="
	fieldByKeys	Booléen	"="
	id	Chaîne	N/A
	self	Chaîne	N/A
	key	Chaîne	N/A
	Champs rendus	Struct	N/A

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	propriétés	Liste	"="
	noms	Struct	N/A
	schéma	Struct	N/A
	transitions	Liste	N/A
	opérations	Struct	N/A
	modifier la méta	Struct	N/A
	journal des modifications	Struct	N/A
	Représentations versionnées	Struct	N/A
	fields	Liste	"="
	fieldsToInclude	Struct	N/A
	Messages d'avertissement	Liste	N/A
	créé	DateTime	N/A
	Date du journal de travail	DateTime	N/A
IssueEvents	id	Entier	N/A
	name	Chaîne	N/A
Champs du problème	id	Chaîne	N/A
	key	Chaîne	N/A

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	name	Chaîne	N/A
	personnalisé	Booléen	N/A
	commandable	Booléen	N/A
	navigable	Booléen	N/A
	recherchable	Booléen	N/A
	Noms des clauses	Liste	N/A
	scope	Struct	N/A
	schéma	Struct	N/A
Configurations des champs de problèmes	est par défaut	Booléen	"="
	query	Chaîne	"="
	id	Entier	"="
	name	Chaîne	N/A
	description	Chaîne	N/A
Type de lien vers le problème	id	Chaîne	N/A
	name	Chaîne	N/A
	vers l'intérieur	Chaîne	N/A
	vers l'extérieur	Chaîne	N/A
	self	Chaîne	N/A
Schémas de notification des problèmes	développer	Chaîne	"="
	self	Chaîne	N/A

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	id	Entier	N/A
	name	Chaîne	N/A
	description	Chaîne	N/A
	notificationScheme Events	Liste	N/A
	scope	Struct	N/A
Priorité du problème	self	Chaîne	N/A
	Couleur de l'état	Chaîne	N/A
	description	Chaîne	N/A
	URL de l'icône	Chaîne	N/A
	name	Chaîne	N/A
	id	Chaîne	N/A
	est par défaut	Booléen	N/A
Résolutions aux problèmes	self	Chaîne	N/A
	id	Chaîne	N/A
	description	Chaîne	N/A
	name	Chaîne	N/A
Schéma de sécurité des problèmes	self	Chaîne	N/A
	id	Entier	N/A
	name	Chaîne	N/A

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	description	Chaîne	N/A
	defaultSecurityLevelId	Entier	N/A
	niveaux	Liste	N/A
Type de problème	self	Chaîne	N/A
	id	Chaîne	N/A
	description	Chaîne	N/A
	URL de l'icône	Chaîne	N/A
	name	Chaîne	N/A
	sous-tâche	Booléen	N/A
	Avatar Arid	Entier	N/A
	entityId	Chaîne	N/A
	Niveau hiérarchique	Entier	N/A
	scope	Struct	N/A
	orderBy	Chaîne	"="
Schéma des types de problèmes	développer	Chaîne	"="
	queryString	Chaîne	"="
	id	Chaîne	N/A
	name	Chaîne	N/A
	description	Chaîne	N/A
	defaultIssueTypeId	Chaîne	N/A

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	est par défaut	Booléen	N/A
Schéma d'écran des types de problèmes	queryString	Chaîne	"="
	orderBy	Chaîne	"="
	développer	Chaîne	"="
	id	Chaîne	"="
	name	Chaîne	N/A
	description	Chaîne	N/A
Réglages Jira	key	Chaîne	N/A
	Filtre clé	Chaîne	"="
	id	Chaîne	N/A
	value	Chaîne	N/A
	name	Chaîne	N/A
	desc	Chaîne	N/A
	type	Chaîne	N/A
	defaultValue	Chaîne	N/A
	exemple	Chaîne	N/A
	allowedValues	Liste	N/A
Paramètres avancés de Jira	id	Chaîne	N/A
	key	Chaîne	N/A
	value	Chaîne	N/A

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	name	Chaîne	N/A
	desc	Chaîne	N/A
	type	Chaîne	N/A
	defaultValue	Chaîne	N/A
	exemple	Chaîne	N/A
	allowedValues	Liste	N/A
Paramètres globaux de Jira	Activation du vote	Booléen	N/A
	Activé pour le visionnage	Booléen	N/A
	unassignedIssuesAllowed	Booléen	N/A
	subTasksEnabled	Booléen	N/A
	issueLinkingEnabled	Booléen	N/A
	timeTrackingEnabled	Booléen	N/A
	Pièces jointes activées	Booléen	N/A
	timeTrackingConfiguration	Struct	N/A
Étiquette	values	Liste	N/A
Moi-même	développeur	Chaîne	"="
	self	Chaîne	N/A

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	accountId	Chaîne	N/A
	Type de compte	Chaîne	N/A
	Adresse e-mail	Chaîne	N/A
	URL des avatars	Chaîne	N/A
	displayName	Chaîne	N/A
	actif	Booléen	N/A
	Fuseau horaire	Chaîne	N/A
	locale	Chaîne	N/A
	groups	Struct	N/A
	Rôles de l'application	Struct	N/A
Autorisations	id	Chaîne	N/A
	key	Chaîne	N/A
	name	Chaîne	N/A
	type	Chaîne	N/A
	description	Chaîne	N/A
	Avoir la permission	Booléen	N/A
	Clé obsolète	Booléen	N/A
Projet	orderBy	Chaîne	"="
	clés	Liste	"="
	query	Chaîne	"="

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	Type de clé	Chaîne	"="
	ID de catégorie	Entier	"="
	action	Chaîne	"="
	développer	Chaîne	"="
	status	Liste	"="
	self	Chaîne	N/A
	id	Entier	"="
	key	Chaîne	N/A
	description	Chaîne	N/A
	lead	Struct	N/A
	composants	Liste	N/A
	Types de problèmes	Liste	N/A
	url	Chaîne	N/A
	e-mail	Chaîne	N/A
	Type de destinataire	Chaîne	N/A
	versions	Liste	N/A
	name	Chaîne	N/A
	roles	Struct	N/A
	URL des avatars	Struct	N/A
	Catégorie de projet	Struct	N/A

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	projectTypeKey	Chaîne	N/A
	simplified	Booléen	N/A
	style	Chaîne	N/A
	favori	Booléen	N/A
	est privé	Booléen	N/A
	issueTypeHierarchy	Struct	N/A
	des autorisations	Struct	N/A
	propriétés	Liste	"="
	uuid	Chaîne	N/A
	aperçu	Struct	N/A
	deleted	Booléen	N/A
	retentionTillDate	Chaîne	N/A
	Date supprimée	Chaîne	N/A
	Supprimé par	Struct	N/A
	archived	Booléen	N/A
	Date d'archivage	Chaîne	N/A
	Archivé par	Struct	N/A
	landedPageInfo	Struct	N/A
Catégorie de projet	self	Chaîne	N/A
	id	Chaîne	N/A

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	name	Chaîne	N/A
	description	Chaîne	N/A
Type de projet	key	Chaîne	N/A
	Clé formatée	Chaîne	N/A
	description	Chaîne	N/A
	Désignation : i18NKEY	Chaîne	N/A
	icon	Chaîne	N/A
	color	Chaîne	N/A
Informations sur le serveur	URL de base	Chaîne	N/A
	version	Chaîne	N/A
	Numéros de version	Liste	N/A
	deploymentType	Chaîne	N/A
	Numéro de build	Entier	N/A
	Date de construction	DateTime	N/A
	Heure du serveur	DateTime	N/A
	Informations SCM	Chaîne	N/A
	Titre du serveur	Chaîne	N/A
	Contrôles de santé	Liste	N/A
Users	self	Chaîne	N/A

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	accountId	Chaîne	N/A
	Type de compte	Chaîne	N/A
	Adresse e-mail	Chaîne	N/A
	URL des avatars	Struct	N/A
	displayName	Chaîne	N/A
	actif	Booléen	N/A
	Fuseau horaire	Chaîne	N/A
	locale	Chaîne	N/A
	groups	Struct	N/A
	Rôles de l'application	Struct	N/A
	développer	Chaîne	N/A
Flux de travail	Nom du flux de travail	Chaîne	"="
	développer	Chaîne	"="
	queryString	Chaîne	"="
	orderBy	Chaîne	"="
	est actif	Booléen	"="
	id	Struct	N/A
	description	Chaîne	N/A
	transitions	Liste	N/A
	statuts	Liste	N/A

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	est par défaut	Booléen	N/A
	manigances	Liste	N/A
	projets	Liste	N/A
	hasDraftWorkflow	Booléen	N/A
	opérations	Struct	N/A
	créé	Chaîne	N/A
	updated	Chaîne	N/A
Schéma de workflow	self	Chaîne	N/A
	id	Entier	N/A
	name	Chaîne	N/A
	description	Chaîne	N/A
	Flux de travail par défaut	Chaîne	N/A
	issueTypeMappings	Struct	N/A
	originalDefaultWorkflow	Chaîne	N/A
	originalIssueTypeCartographies	Struct	N/A
	ébauche	Booléen	N/A
	lastModifiedUser	Struct	N/A
	Dernière modification	Chaîne	N/A

Objet	Champ	Type de données	Opérateurs de filtre pris en charge
	updateDraftIfNécessaire	Booléen	N/A
	Types de problèmes	Struct	N/A
Association de projets de schéma de flux de travail	projectId	Entier	"="
	Identifiants du projet	Liste	N/A
	Schéma de flux de travail	Struct	N/A
État du flux de travail	self	Chaîne	N/A
	description	Chaîne	N/A
	URL de l'icône	Chaîne	N/A
	name	Chaîne	N/A
	id	Chaîne	N/A
	StatusCategory	Struct	N/A
Catégorie d'état du flux de travail	self	Chaîne	N/A
	id	Chaîne	N/A
	key	Chaîne	N/A
	Nom de la couleur	Chaîne	N/A
	name	Chaîne	N/A

Requêtes de partitionnement

Vous pouvez fournir l'option Spark supplémentaire `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ce paramètre, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `NUM_PARTITIONS`: le nombre de partitions.

Exemple :

```
jiraCloud_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="JiraCloud",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "issue",  
        "API_VERSION": "v2",  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Options de connexion Jira Cloud

Les options de connexion pour Jira Cloud sont les suivantes :

- `ENTITY_NAME`(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Jira Cloud.
- `API_VERSION`(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Jira Cloud Rest que vous souhaitez utiliser. Par exemple : v2.
- `DOMAIN_URL`(String) - (Obligatoire) Le Jira Cloud ID que vous souhaitez utiliser.
- `SELECTED_FIELDS`(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- `FILTER_PREDICATE`(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- `QUERY`(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- `NUM_PARTITIONS`(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Limitations et remarques relatives au connecteur Jira Cloud

Voici les limitations ou remarques relatives au connecteur Jira Cloud :

- L'Containsoopérateur ne fonctionne pas avec le resourceName champ, qui est du type de données String.

Connexion à Kustomer

Kustomer est une puissante plateforme d'expérience client qui réunit tout ce dont vous avez besoin pour mieux servir vos clients dans un seul easy-to-use outil.

Rubriques

- [AWS Glue support pour Kustomer](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Kustomer](#)
- [Configuration des connexions Kustomer](#)
- [Lecture à partir d'entités Kustomer](#)
- [Options de connexion Kustomer](#)
- [Limitations des clients](#)

AWS Glue support pour Kustomer

AWS Glue prend en charge Kustomer comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Kustomer.

Soutenu en tant que cible ?

Non.

Versions de l'API Kustomer prises en charge

Les versions suivantes de l'API Kustomer sont prises en charge :

- v1

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Kustomer

Avant de pouvoir AWS Glue transférer des données de Kustomer vers des destinations prises en charge, vous devez répondre aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un compte Kustomer qui contient les données que vous souhaitez transférer.
- Dans les paramètres de votre compte, vous avez créé une clé API. Pour de plus amples informations, veuillez consulter [Création d'une clé d'API](#).
- Vous fournissez la clé d'API AWS Glue lors de la création de la connexion.

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Kustomer.

Création d'une clé d'API

Pour créer une clé d'API que vous utiliserez pour créer une connexion pour le connecteur Kustomer dans AWS Glue Studio :

1. Connectez-vous au tableau de [bord Kustomer à l'aide de vos](#) informations d'identification.
2. Choisissez l'icône Paramètres dans le menu de gauche.
3. Développez le menu déroulant Sécurité et sélectionnez Clés d'API.
4. Sur la page de création d'une clé d'API, sélectionnez Ajouter une clé d'API dans le coin supérieur droit.
5. Renseignez les entrées obligatoires pour la clé d'API en cours de création.
 - Nom : n'importe quel nom pour votre clé d'API.
 - Rôles : « org » doit être sélectionné pour que le APIs Kustomer fonctionne.
 - Expire (en jours) : le nombre de jours pendant lesquels vous souhaitez que la clé d'API soit valide. Vous pouvez le conserver sous la forme Never expires, si cela convient à votre cas d'utilisation.
6. Sélectionnez Create (Créer).
7. Stockez la valeur de la clé API (jeton) pour une utilisation ultérieure afin de créer une connexion pour le connecteur Kustomer dans AWS Glue Studio.

Configuration des connexions Kustomer

Pour configurer une connexion Kustomer :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir le secret du consommateur de l'application connectée dont la clé est la clé. `apiKey`
 - b. Remarque : vous devez créer un secret pour vos connexions dans AWS Glue.
1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Sous Connexions, choisissez Créer une connexion.
 - b. Lorsque vous sélectionnez une source de données, sélectionnez Kustomer.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture à partir d'entités Kustomer

Prérequis

Un objet Kustomer dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet, tel que Brands ou Cards. Le tableau suivant indique les entités prises en charge.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Marques	Non	Oui	Non	Oui	Non
Cartes	Non	Oui	Non	Oui	Non
Réglages du chat	Non	Non	Non	Oui	Non
Entreprises	Oui	Oui	Oui	Oui	Oui
Conversations	Oui	Oui	Oui	Oui	Oui
Les clients	Oui	Oui	Oui	Oui	Oui
Recherches de clients épinglées	Non	Oui	Non	Oui	Non
Position des recherches du client	Non	Non	Non	Oui	Non
Hooks pour e-mails	Non	Oui	Non	Oui	Non
Hooks Web	Non	Oui	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Articles de la KB	Non	Oui	Non	Oui	Non
Catégories KB	Non	Oui	Non	Oui	Non
Formulaires KB	Non	Oui	Non	Oui	Non
Routes KB	Non	Oui	Non	Oui	Non
Balises KB	Non	Oui	Non	Oui	Non
Modèles KB	Non	Oui	Non	Oui	Non
Thèmes KB	Non	Oui	Non	Oui	Non
Classes	Non	Oui	Non	Oui	Non
KViews	Non	Oui	Non	Oui	Non
Messages	Oui	Oui	Oui	Oui	Oui
Remarques	Oui	Oui	Oui	Oui	Oui
Notifications	Non	Oui	Non	Oui	Non

Exemple :

```
Kustomer_read = glueContext.create_dynamic_frame.from_options(
    connection_type="kustomer",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "brands",
        "API_VERSION": "v1"
    }
)
```


Informations sur l'entité et le champ du client

Pour plus d'informations sur les entités et les détails des champs, voir :

- [Marques](#)
- [Cartes](#)
- [Réglages du chat](#)
- [Les entreprises](#)
- [Conversations](#)
- [Clientèle](#)
- [Recherches de clients épinglées](#)
- [Le client recherche des postes](#)
- [E-Mail de Hooks](#)
- [Hooks Web](#)
- [Articles de la KB](#)
- [Catégories KB](#)
- [Formulaires KB](#)
- [Routes KB](#)
- [Balises KB](#)
- [Modèles KB](#)
- [Thèmes KB](#)
- [Classes](#)
- [Kviews](#)
- [Messages](#)
- [Remarques](#)
- [Notifications](#)

API Kustomer v1

Entité	Champ	Type de données	Opérateurs pris en charge
Marques	id	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	name	Chaîne	N/A
	URL de l'icône	Chaîne	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	Modifié à	DateTime	N/A
	default	Booléen	N/A
Cartes	id	Chaîne	N/A
	name	Chaîne	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	Modifié à	DateTime	N/A
	description	Chaîne	N/A
	url	Chaîne	N/A
Réglages du chat	contextes	Liste	N/A
	id	Chaîne	N/A
	Version des paramètres	Entier	N/A
	Type de widget	Chaîne	N/A
	version	Entier	N/A
	Nom de l'équipe	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	salutation	Chaîne	N/A
	réponse automatique	Chaîne	N/A
	embedIconUrl	Chaîne	N/A
	embedIconColor	Chaîne	N/A
	fallbackEmailSubject	Chaîne	N/A
	fallbackEmailIntroduction	Chaîne	N/A
	enabled	Booléen	N/A
	outboundChatEnabled	Booléen	N/A
	updatedAt	DateTime	N/A
	Modifié à	DateTime	N/A
	Message en dehors des heures d'ouverture	Chaîne	N/A
	offhoursImageUrl	Chaîne	N/A
	Chat verrouillable	Booléen	N/A
	Pas d'histoire	Booléen	N/A
	Désactiver les pièces jointes	Booléen	N/A
	Contrôle du volume	Struct	N/A
	singleSessionChat	Booléen	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	showTypingIndicatorWeb	Booléen	N/A
Entreprises	id	Chaîne	N/A
	name	Chaîne	=, !=, CONTIENT
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	Modifié à	DateTime	=, !=, >, >=, <, <=, ENTRE
	balises	Liste	N/A
	domains	Liste	N/A
	e-mails	Liste	N/A
	téléphones	Liste	N/A
	whatsapps	Liste	N/A
	réseaux sociaux	Liste	N/A
	les urls	Liste	N/A
	les lieux	Liste	N/A
	roleGroupVersions	Liste	N/A
	réverend	Entier	N/A
Conversations	id	Chaîne	N/A
	name	Chaîne	=, !=, CONTIENT
	aperçu	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	canaux	Liste	N/A
	status	Chaîne	=, !=, CONTIENT
	Nombre de messages	Entier	=, !=, >, >=, <, <=
	Nombre de notes	Entier	=, !=, >, >=, <, <=
	satisfaction	Entier	=, !=, >, >=, <, <=
	Niveau de satisfaction	Struct	N/A
	createdAt	DateTime	=, !=, >, >=, <, <=, ENTRE
	updatedAt	DateTime	=, !=, >, >=, <, <=, ENTRE
	Modifié à	DateTime	=, !=, >, >=, <, <=, ENTRE
	lastActivityAt	DateTime	N/A
	spam	Booléen	N/A
	terminé	Booléen	=, !=
	Terminé à	DateTime	=, !=, >, >=, <, <=, ENTRE
	Raison terminée	Chaîne	CONTAINS
	endedByType	Chaîne	N/A
	Importé à	Chaîne	N/A
	balises	Liste	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Tags suggérés	Liste	N/A
	sentiment	Chaîne	N/A
	prédictions	Liste	N/A
	Raccourcis suggérés	Liste	N/A
	firstMessageIn	Struct	N/A
	firstMessageOut	Struct	N/A
	lastMessageIn	Struct	N/A
	lastMessageOut	Struct	N/A
	lastMessageAt	DateTime	=, !=, >, >=, <, <=, ENTRE
	lastMessageUnrespondedÀ	Struct	N/A
	lastMessageUnrespondedToSinceLastDone	Struct	N/A
	Utilisateurs assignés	Liste	N/A
	Équipes assignées	Liste	N/A
	Première réponse	Struct	N/A
	firstResponseSinceLastDone	Struct	N/A
	Dernière réponse	Struct	N/A
	Tout d'abord fait	Struct	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Dernière opération	Struct	N/A
	direction	Chaîne	=, !=, CONTIENT
	lastMessageDirection	Chaîne	N/A
	outboundMessageCount	Entier	N/A
	inboundMessageCount	Entier	N/A
	réverend	Entier	N/A
	priority	Entier	=, !=, >, >=, <, <=
	roleGroupVersions	Liste	N/A
	Accessoire Override	Liste	N/A
	assistant	Struct	N/A
	phase	Chaîne	N/A
	Compétences	Liste	N/A
	matchedTimeBasedRègles	Liste	N/A
Les clients	id	Chaîne	N/A
	name	Chaîne	=, !=, CONTIENT
	displayName	Chaîne	N/A
	Couleur de l'écran	Chaîne	N/A
	Icône d'affichage	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	ID externe	Chaîne	=, ! =, CONTIENT
	Identifiants externes	Liste	N/A
	sharedExternalIds	Liste	N/A
	e-mails	Liste	N/A
	E-mails partagés	Liste	N/A
	téléphones	Liste	N/A
	Téléphones partagés	Liste	N/A
	whatsapps	Liste	N/A
	Identifiants Facebook	Liste	N/A
	Identifiants Instagram	Liste	N/A
	réseaux sociaux	Liste	N/A
	Réseaux sociaux partagés	Liste	N/A
	les urls	Liste	N/A
	les lieux	Liste	N/A
	Utilisateurs actifs	Liste	N/A
	les observateurs	Liste	N/A
	Emplacement récent	Struct	N/A
	locale	Chaîne	=, ! =, CONTIENT
	Fuseau horaire	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	gender	Chaîne	=, !=, CONTIENT
	createdAt	DateTime	=, !=, >, >=, <, <=, ENTRE
	updatedAt	DateTime	=, !=, >, >=, <, <=, ENTRE
	Modifié à	DateTime	=, !=, >, >=, <, <=, ENTRE
	lastActivityAt	DateTime	N/A
	deleted	Booléen	N/A
	Dernière conversation	Struct	N/A
	La conversation compte	Struct	N/A
	aperçu	Struct	N/A
	balises	Liste	N/A
	Statut progressif	Chaîne	=, !=, CONTIENT
	verified	Booléen	N/A
	réverend	Entier	N/A
	Articles récents	Liste	N/A
	Lang par défaut	Chaîne	=, !=, CONTIENT
	Niveau de satisfaction	Struct	N/A
	roleGroupVersions	Liste	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Accessoire Override	Liste	N/A
	Nom de l'entreprise	Chaîne	N/A
	firstName	Chaîne	N/A
	lastName	Chaîne	N/A
Recherches de clients épinglées	id	Chaîne	N/A
	search	Chaîne	N/A
	createdAt	DateTime	N/A
Le client recherche des postes	id	Chaîne	N/A
	positions	Liste	N/A
	enfants	Liste	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	Modifié à	DateTime	N/A
	réverend	Entier	N/A
Hooks pour e-mails	id	Chaîne	N/A
	description	Chaîne	N/A
	debug	Booléen	N/A
	e-mail	Chaîne	N/A
	eventName	Chaîne	N/A
	title	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	hachage	Chaîne	N/A
	key	Chaîne	N/A
	createdAt	DateTime	N/A
	Modifié à	DateTime	N/A
	updatedAt	DateTime	N/A
Hooks Web	id	Chaîne	N/A
	description	Chaîne	N/A
	eventName	Chaîne	N/A
	hachage	Chaîne	N/A
	url	Chaîne	N/A
	createdAt	DateTime	N/A
	Modifié à	DateTime	N/A
	updatedAt	DateTime	N/A
	title	Chaîne	N/A
	version	Entier	N/A
	debug	Booléen	N/A
Articles de la KB	id	Chaîne	N/A
	hachage	Chaîne	N/A
	title	Chaîne	N/A
	source	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	status	Chaîne	N/A
	scope	Chaîne	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	deleted	Booléen	N/A
	Supprimé à	DateTime	N/A
	Modifié à	DateTime	N/A
	Publié sur	DateTime	N/A
	balises	Liste	N/A
	categories	Liste	N/A
	Bases de connaissances	Liste	N/A
	Méta-titre	Chaîne	N/A
	Méta-description	Chaîne	N/A
	Méta-mots clés	Liste	N/A
	Versions langagières	Struct	N/A
	Derniers langs	Struct	N/A
Catégories KB	id	Chaîne	N/A
	hachage	Chaîne	N/A
	createdAt	DateTime	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Modifié à	DateTime	N/A
	updatedAt	DateTime	N/A
	publié	Booléen	N/A
	positions	Liste	N/A
	Catégorie Positions	Liste	N/A
	racine	Booléen	N/A
	langs	Struct	N/A
Formulaires KB	id	Chaîne	N/A
	name	Chaîne	N/A
	limace	Chaîne	N/A
	hachage	Chaîne	N/A
	body	Chaîne	N/A
	disposition	Liste	N/A
	Mise en page V2	Liste	N/A
	ComposantsV2	Struct	N/A
	conditions	Struct	N/A
	avancé	Booléen	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	Publié sur	DateTime	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Modifié à	Chaîne	N/A
	publié	Booléen	N/A
	extraits	Liste	N/A
	recaptcha	Booléen	N/A
	klass	Chaîne	N/A
	channel	Chaîne	N/A
	déviation	Booléen	N/A
	formHookEnabled	Booléen	N/A
	Réponse de	Chaîne	N/A
	wcag	Booléen	N/A
Routes KB	id	Chaîne	N/A
	url	Chaîne	N/A
	Type de routeur	Chaîne	N/A
	ID routable	Chaîne	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	Modifié à	DateTime	N/A
Balises KB	id	Chaîne	N/A
	name	Chaîne	N/A
	createdAt	DateTime	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	updatedAt	DateTime	N/A
	Modifié à	DateTime	N/A
Modèles KB	id	Chaîne	N/A
	title	Chaîne	N/A
	description	Chaîne	N/A
	bêta	Booléen	N/A
	manifeste	Struct	N/A
	Extraits JSX	Liste	N/A
	images	Liste	N/A
	version	Chaîne	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
Thèmes KB	id	Chaîne	N/A
	name	Chaîne	N/A
	actif	Booléen	N/A
	default	Booléen	N/A
	lastfileUpdatedAt	DateTime	N/A
	personnalisé	Booléen	N/A
	status	Chaîne	N/A
	templateVersionId	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Titre du modèle	Chaîne	N/A
	Version du modèle	Chaîne	N/A
	manifeste	Struct	N/A
	Extraits de configuration	Liste	N/A
	Extraits JSX	Liste	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	Modifié à	DateTime	N/A
	réverend	Entier	N/A
Classes	id	Chaîne	N/A
	name	Chaîne	N/A
	icon	Chaîne	N/A
	color	Chaîne	N/A
	Application désactivée	Booléen	N/A
	status	Chaîne	N/A
	updatedAt	DateTime	N/A
	createdAt	DateTime	N/A
	s3 DataUrl	Chaîne	N/A
KViews	id	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	ressource	Chaîne	N/A
	modèle	Chaîne	N/A
	context	Chaîne	N/A
	méta	Struct	N/A
	Application désactivée	Booléen	N/A
	enabled	Booléen	N/A
	avancé	Booléen	N/A
	disposition	Liste	N/A
	composants	Struct	N/A
	conditions	Struct	N/A
	réverend	Entier	N/A
	createdAt	DateTime	N/A
	Modifié à	DateTime	N/A
	updatedAt	DateTime	N/A
Notifications	id	Chaîne	N/A
	name	Chaîne	N/A
	status	Chaîne	N/A
	event	Struct	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
Messages	id	Chaîne	N/A
	ID externe	Chaîne	N/A
	channel	Chaîne	=, !=, CONTIENT
	app	Chaîne	N/A
	size	Entier	=, !=, >, >=, <, <=
	direction	Chaîne	=, !=, CONTIENT
	aperçu	Chaîne	N/A
	subject	Chaîne	N/A
	méta	Struct	N/A
	status	Chaîne	=, !=, CONTIENT
	Type de direction	Chaîne	=, !=, CONTIENT
	Équipes assignées	Liste	N/A
	Utilisateurs assignés	Liste	N/A
	Erreur ORI	DateTime	=, !=, >, >=, <, <=, ENTRE
	auto	Booléen	=, !=
	Envoyé	DateTime	=, !=, >, >=, <, <=, ENTRE
	createdAt	DateTime	=, !=, >, >=, <, <=, ENTRE
	updatedAt	DateTime	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	Modifié à	DateTime	N/A
	expurgé	Booléen	N/A
	createdByTeams	Liste	N/A
	réverend	Entier	N/A
	réactions	Liste	N/A
	Détections d'intention	Liste	N/A
Remarques	id	Chaîne	N/A
	body	Chaîne	CONTAINS
	createdAt	DateTime	=, !=, >, >=, <, <=, ENTRE
	updatedAt	DateTime	=, !=, >, >=, <, <=, ENTRE
	Modifié à	DateTime	=, !=, >, >=, <, <=, ENTRE
	createdByTeams	Liste	N/A

Requêtes de partitionnement

Partitionnement basé sur le terrain

Vous pouvez fournir les options supplémentaires de Spark

PARTITION_FIELDLOWER_BOUND,UPPER_BOUND, et NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- **PARTITION_FIELD**: le nom du champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**: une valeur de limite inférieure inclusive du champ de partition choisi.

Pour le **DateTime** champ, nous acceptons la valeur au format ISO.

Exemple de valeur valide :

```
"2023-01-15T11:18:39.205Z"
```

- **UPPER_BOUND**: une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**: le nombre de partitions.

Les détails relatifs à la prise en charge des champs de partitionnement par entité sont présentés dans le tableau suivant :

Nom de l'entité	Champs de partitionnement	Type de données
Entreprises	Modifié à	DateTime
Conversations	CreatedAt, UpdatedAt, ModifiedAt, EndedAt, lastMessageAt	DateTime
	Nombre de messages, nombre de notes	BigInteger
	priority	Entier
Clients	CreatedAt, UpdatedAt, ModifiedAt	DateTime
Messages	Erreur Rat, SentAt, CreatedAt	DateTime
	size	BigInteger
Remarques	CreatedAt, UpdatedAt, ModifiedAt	DateTime

Exemple :

```
Kustomer_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="kustomer",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "conversation",  
        "API_VERSION": "v1",  
        "PARTITION_FIELD": "createdAt"  
        "LOWER_BOUND": "2023-01-15T11:18:39.205Z"  
        "UPPER_BOUND": "2023-02-15T11:18:39.205Z"  
        "NUM_PARTITIONS": "2"  
    }  
)
```

Options de connexion Kustomer

Les options de connexion pour Kustomer sont les suivantes :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Kustomer.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Kustomer Rest que vous souhaitez utiliser.
- SELECTED_FIELDS(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- FILTER_PREDICATE(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- QUERY(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- PARTITION_FIELD(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- LOWER_BOUND(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- UPPER_BOUND(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS(Entier) - Valeur par défaut : 1. Utilisée pour lire. Nombre de partitions à lire.
- INSTANCE_URL(Chaîne) - (Obligatoire) Utilisé pour la lecture. URL de l'instance du client.

Limitations des clients

Voici les limitations ou remarques relatives à Kustomer :

- L'Customer Searchentité n'est pas prise en charge car la documentation de l'API Kustomer n'a déclaré aucun point de terminaison pour elle.
- La prise en charge de la filtration et du transfert incrémentiel sur l'Klassentité n'est pas prise en charge.
- La commande par peut être prise en charge dans plusieurs champs applicables dans une seule demande.

Cependant, il a été observé que l'ordre par fonctionnalité sur plusieurs champs se comportait de manière incohérente du point de vue du SaaS pour certaines combinaisons. C'est imprévisible car il peut y avoir « n » combinaisons susceptibles d'afficher des résultats de tri incorrects. Par exemple :

Pour l'Customersentité, le tri par `progressiveStatus desc`, `name asc` ne donne pas le résultat de tri correct. Il trie uniquement en fonction de la `progressiveStatus` commande. Si un tel comportement est observé, vous pouvez utiliser un seul champ pour commander.

- Le tri par sur le champ « id » n'est pris en charge que par les Messages entités Conversations et en tant que paramètre de requête. Par exemple : `https://api.kustomerapp.com/v1/ des conversations ? sort=desc` (Ceci trie les résultats par « id » dans l'ordre décroissant.)

De plus, tout autre filtre ou commande sur un autre champ est traduit dans un corps de requête POST dont le point de terminaison de l'API est POST `https://api.kustomerapp.com/v1/ clients/search`. Pour permettre la prise en charge de la commande par « identifiant » dans Conversations et Messages, soit seul le tri par identifiant doit être présent, soit tout autre filtre et/ou ordre par sur tout autre champ applicable.

- Kustomer permet de récupérer un maximum de 10 000 enregistrements, qu'il s'agisse d'une demande filtrée ou non filtrée. En raison de cette limitation, toute entité détenant plus de 10 000 enregistrements subira une perte de données. Il existe deux solutions possibles pour atténuer partiellement ce problème :
 - Appliquez des filtres pour récupérer un ensemble d'enregistrements spécifique.
 - Si un filtre est appliqué à plus de 10 000 enregistrements, appliquez une valeur de filtre successive dans une nouvelle demande ultérieure ou appliquez des plages dans les filtres. Par exemple :

FilterExpression de la première demande : `modifiedAt >= 2022-03-15T05:26:23.000Z and modifiedAt < 2023-03-15T05:26:23.000Z`

Supposons que cela dépasse la limite d'enregistrement de 10 000.

Une autre requête peut être déclenchée avec FilterExpression : `modifiedAt >= 2023-03-15T05:26:23.000Z`

- En tant que comportement SaaS, l'CONTAINSopérateur de Kustomer prend en charge la mise en correspondance uniquement sur des mots complets et non sur des correspondances partielles au sein d'un mot. Par exemple : « body CONTAINS 'test record' » correspondra à un enregistrement ayant « test » dans le champ « body ». Cependant, « body CONTAINS 'test' » ne correspondra pas à un enregistrement contenant testAnotherRecord « » dans le champ « body ».

Connexion à LinkedIn

LinkedIn est un outil de marketing payant qui permet d'accéder aux réseaux LinkedIn sociaux par le biais de diverses publications sponsorisées et d'autres méthodes. LinkedIn est un puissant outil marketing permettant aux entreprises B2B de créer des prospects, de se faire reconnaître en ligne, de partager du contenu, etc.

Rubriques

- [AWS Glue support pour LinkedIn](#)
- [Politiques contenant les opérations d'API pour la création et l'utilisation de connexions](#)
- [Configuration LinkedIn](#)
- [Configuration des LinkedIn connexions](#)
- [Lecture à partir d' LinkedIn entités](#)
- [LinkedIn options de connexion](#)
- [Création d'un LinkedIn compte](#)
- [Limites](#)

AWS Glue support pour LinkedIn

AWS Glue prend en charge LinkedIn les éléments suivants :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données à partir de LinkedIn.

Soutenu en tant que cible ?

Non

Versions LinkedIn d'API prises en charge

202406 (juin 2024)

Politiques contenant les opérations d'API pour la création et l'utilisation de connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode précédente, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#) — Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#) — Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs

bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration LinkedIn

Avant de pouvoir AWS Glue utiliser le transfert depuis LinkedIn, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Tu as un LinkedIn compte. Pour plus d'informations sur la création d'un compte, consultez la section [Création d'un LinkedIn compte](#).
- Votre LinkedIn compte est activé pour accéder à l'API.
- Vous avez créé une OAuth2 API intégration dans votre LinkedIn compte. Cette intégration fournit les informations d'identification du client qui AWS Glue permettent d'accéder à vos données en toute sécurité lorsqu'il effectue des appels authentifiés vers votre compte. Pour de plus amples informations, veuillez consulter [the section called "Création d'un LinkedIn compte"](#).

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre LinkedIn compte. Pour les connexions classiques, vous n'avez rien d'autre à faire dans LinkedIn.

Configuration des LinkedIn connexions

LinkedIn prend en charge le type de AUTHORIZATION_CODE subvention pour OAuth2.

Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Les utilisateurs peuvent choisir de créer leur propre application connectée LinkedIn et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés LinkedIn vers pour se connecter et autoriser AWS Glue l'accès à leurs ressources.

Ce type de subvention donne lieu à la fois à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès expire 60 jours après sa création. Un nouveau jeton d'accès peut être obtenu à l'aide du jeton d'actualisation.

Pour consulter LinkedIn la documentation publique sur la création d'une application connectée pour Authorization Code OAuth Flow, consultez [Authorization Code Flow \(à 3 étapes\)](#). OAuth

Configuration d'une LinkedIn connexion

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET comme clé.
 - Pour l'application connectée AWS gérée : secret vide ou secret avec une valeur temporaire.

Note

Il est indispensable de créer un secret par connexion AWS Glue.

2. Dans le AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 1. Lorsque vous sélectionnez un type de connexion, sélectionnez LinkedIn.
 2. Fournissez l' LinkedIn environnement.
 3. Sélectionnez le rôle IAM pour lequel AWS Glue vous pouvez assumer et qui dispose des autorisations nécessaires pour effectuer les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

4. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 5. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture à partir d' LinkedIn entités

Prérequis

Un LinkedIn objet que vous aimeriez lire. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Comptes publicitaires	Oui	Oui	Oui	Oui	Non
Campagnes	Oui	Oui	Oui	Oui	Non
Groupes de campagne	Oui	Oui	Oui	Oui	Non
Créatifs	Oui	Oui	Oui	Oui	Non
Analyses publicitaires	Oui	Non	Non	Oui	Non
Toutes les analyses publicitaires AdAcocunts	Oui	Non	Non	Oui	Non
Analyse publicitaire :	Oui	Non	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
toutes les campagnes					
Toutes les analyses publicitaires CampaignGroups	Oui	Non	Non	Oui	Non
Toutes les analyses publicitaires AdCreatives	Oui	Non	Non	Oui	Non
Partager les statistiques	Oui	Non	Non	Oui	Non
Statistiques de la page	Oui	Non	Non	Oui	Non
Statistiques sur les abonnés	Oui	Non	Non	Oui	Non

Exemple

```

netsuiteerp_read = glueContext.create_dynamic_frame.from_options(
    connection_type="linkedin",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "adaccounts",
        "API_VERSION": "202406"
    }
)

```

LinkedIn détails de l'entité et du champ

Type de données de champ	Opérateurs de filtre pris en charge
Chaîne	=
DateTime	ENTRE, =
Numérique	=
Booléen	=

LinkedIn options de connexion

Les options de connexion suivantes sont disponibles pour LinkedIn :

- **ENTITY_NAME**(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans LinkedIn. Par exemple, AdAccounts.
- **API_VERSION**(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. LinkedIn Version de l'API Rest que vous souhaitez utiliser. La valeur sera 202406, car seule la version 202406 LinkedIn est actuellement prise en charge.
- **SELECTED_FIELDS**(Liste<String>) — Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'entité sélectionnée.
- **FILTER_PREDICATE**(String) — Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) — Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

Création d'un LinkedIn compte

Création d'une LinkedIn application et d' OAuth informations d'identification

1. Accédez à la page de votre réseau de LinkedIn développeurs et connectez-vous à l'aide des informations d'identification de votre LinkedIn compte.
2. Accédez à la page Mes applications et choisissez Créer une application pour créer une nouvelle LinkedIn application.
3. Entrez les informations suivantes dans le formulaire d'inscription à l'application :

- Nom de l'entreprise — Sélectionnez une entreprise existante ou créez-en une nouvelle.
 - Nom — Entrez le nom de l'application.
 - Description — Entrez la description de l'application.
 - Logo de l'application — Sélectionnez un fichier image comme logo de votre application.
 - Utilisation de l'application — Sélectionnez l'utilisation de votre application.
 - URL du site Web — Entrez l'URL du site Web qui contient des informations détaillées sur votre application.
 - Adresse e-mail professionnelle — Entrez votre adresse e-mail professionnelle.
 - Numéro de téléphone professionnel — Entrez votre numéro de téléphone professionnel.
 - LinkedIn Conditions d'utilisation de l'API — Lisez et acceptez.
4. Une fois le formulaire d'inscription à l'application rempli, choisissez Soumettre.

Vous serez redirigé vers la page d'authentification, où les clés d'authentification (ID client et secret client) et d'autres informations pertinentes seront affichées.

5. Si votre application Web nécessite l'accès à l'adresse e-mail de l'utilisateur depuis son LinkedIn compte, sélectionnez `r_emailaddressautorisation`. En outre, vous pouvez spécifier la redirection autorisée URLs pour votre LinkedIn application.

Création d'une page dans le LinkedIn compte

1. Accédez à [LinkedIn Developer Products](#).
2. Dans le coin supérieur droit de la page Produits pour LinkedIn développeurs, sélectionnez Mes applications.
3. Dans le coin supérieur droit de la page Mes applications, sélectionnez Créer une application.
4. Sur la page Créer une application, entrez le nom de votre application dans le champ Nom de l'application.
5. Dans le champ LinkedIn Page, saisissez le nom ou l'URL de la page de votre entreprise.

Note

Si vous n'avez pas de LinkedIn page, vous pouvez en créer une en sélectionnant Créer une nouvelle LinkedIn.

6. Dans le champ URL de la politique de confidentialité, entrez l'URL de votre politique de confidentialité.
7. Choisissez Importer un logo pour télécharger une image à afficher aux utilisateurs lorsqu'ils l'autorisent avec votre application.
8. Dans la section Accord juridique, sélectionnez J'ai lu et j'accepte ces conditions.
9. Choisissez Créer une application.

Votre nouvelle application sera créée et sera disponible sous l'onglet Mes applications.

Publier des annonces de campagne dans LinkedIn

1. Connectez-vous au gestionnaire de campagne.
2. Sélectionnez un groupe de campagne existant ou choisissez Créer pour en créer un nouveau.
3. Sélectionnez votre objectif.
4. Sélectionnez votre groupe, votre budget et votre calendrier.
5. Développez votre public cible.
6. Sélectionnez le format de votre annonce.
7. Sélectionnez votre budget et votre calendrier.
8. Configurez vos annonces.
9. Révision et lancement.

Limites

Pour les champs `Analyticsad_analytics_all_adAccounts`, `ad_analytics_all_campaigns`, `ad_analytics_all_campaign_groups`, et `ad_analytics_all_adCreatives` un filtre est obligatoire pour récupérer les enregistrements.

Connexion à Mailchimp

Mailchimp est une plateforme all-in-one marketing qui vous aide à gérer et à communiquer avec vos clients, clients et autres parties intéressées. Leur approche du marketing met l'accent sur des pratiques saines de gestion des contacts, des e-mails magnifiquement conçus, des flux de travail automatisés uniques et une analyse de données puissante. Si vous utilisez Mailchimp, vous pouvez vous connecter AWS Glue à votre compte Mailchimp. Vous pouvez ensuite utiliser Mailchimp comme

source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre Mailchimp et des AWS services ou d'autres applications prises en charge.

Rubriques

- [AWS Glue support pour Mailchimp](#)
- [Politiques contenant les opérations d'API pour la création et l'utilisation de connexions](#)
- [Configuration de Mailchimp](#)
- [Configuration des connexions Mailchimp](#)
- [Lecture à partir d'entités Mailchimp](#)
- [Options de connexion Mailchimp](#)
- [Création d'un compte Mailchimp](#)
- [Limites](#)

AWS Glue support pour Mailchimp

AWS Glue supporte Mailchimp comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Mailchimp.

Soutenu en tant que cible ?

Non.

Versions de l'API Mailchimp prises en charge

3.0

Politiques contenant les opérations d'API pour la création et l'utilisation de connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{  
  "Version": "2012-10-17",  
  "Statement": [  

```



```
{
  "Effect": "Allow",
  "Action": [
    "glue:ListConnectionTypes",
    "glue:DescribeConnectionType",
    "glue:RefreshOAuth2Tokens",
    "glue:ListEntities",
    "glue:DescribeEntity"
  ],
  "Resource": "*"
}
```

Si vous ne souhaitez pas utiliser la méthode précédente, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#) — Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#) — Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Mailchimp

Avant de pouvoir AWS Glue effectuer un transfert depuis Mailchimp, vous devez remplir les conditions suivantes :

Configuration requise

- Vous avez un compte Mailchimp avec e-mail et mot de passe. Pour plus d'informations sur la création d'un compte, consultez [Création d'un compte Mailchimp](#).
- Vous devez avoir créé AWS un compte avec l'accès au service à AWS Glue.

- Assurez-vous d'avoir créé l'une des ressources suivantes. Ces ressources fournissent des informations d'identification qui AWS Glue permettent d'accéder en toute sécurité à vos données lorsque vous passez des appels authentifiés vers votre compte :
- Une application pour développeurs qui prend en charge l'authentification OAuth 2.0. Pour plus d'informations sur la création d'une application pour développeurs, consultez [Création d'un compte Mailchimp](#).

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Mailchimp. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Mailchimp.

Configuration des connexions Mailchimp

Mailchimp prend en charge les deux types de mécanismes d'authentification suivants :

- Mailchimp prend en charge ce type de AUTHORIZATION_CODE subvention.
 - Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. L'utilisateur qui crée une connexion peut par défaut s'appuyer sur une application connectée AWS Glue dont il est propriétaire et où il n'a pas besoin de fournir d'informations OAuth connexes, à l'exception de son identifiant client Mailchimp et de son secret client. La AWS Glue console redirige l'utilisateur vers Mailchimp où il doit se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Mailchimp.
 - Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans Mailchimp et de fournir leur propre ID client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Mailchimp pour se connecter et autoriser l'accès AWS Glue à leurs ressources.
 - Pour consulter la documentation publique de Mailchimp sur la création d'une application connectée pour AUTHORIZATION_CODE OAuth Flow, voir [Accès aux données pour le compte d'autres utilisateurs avec OAuth 2](#).
- Authentification personnalisée : pour consulter la documentation publique de Mailchimp sur la génération des clés d'API requises pour une autorisation personnalisée, consultez [À propos](#) des clés d'API.

Pour configurer une connexion Mailchimp :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :

- OAuth — Pour une application connectée gérée par le client : Secret doit contenir le secret du consommateur de l'application connectée avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
- Authentification personnalisée — Pour l'application connectée gérée par le client : Secret doit contenir l'application connectée Consumer Secret avec « `api_key` » comme clé.

 Note

Il est indispensable de créer un secret par connexion AWS Glue.

2. Dans AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :

- a. Sous Connexions, sélectionnez Créer une connexion.
- b. Lorsque vous sélectionnez une source de données, sélectionnez Mailchimp.
- c. Fournissez le `MailchimpinstanceUrl`.
- d. Sélectionnez le rôle IAM pour lequel AWS Glue vous pouvez assumer et qui dispose des autorisations nécessaires pour effectuer les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- e. Sélectionnez le type d'authentification pour vous connecter à Mailchimp :

- Pour OAuth l'authentification : fournissez l'URL du jeton, l'application cliente gérée par l'utilisateur ClientId du Mailchimp auquel vous souhaitez vous connecter.
 - Pour l'authentification personnalisée, sélectionnez le type d'authentification CUSTOM pour vous connecter à Mailchimp.
- f. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
- g. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.
4. Dans la configuration de votre AWS Glue tâche, fournissez `connectionName` une connexion réseau supplémentaire.

Lecture à partir d'entités Mailchimp

Prérequis

Un objet Mailchimp dont vous souhaitez lire un extrait. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

- [Signalements d'abus](#)
- [Automation](#)
- [Campagnes](#)
- [Détails du clic](#)
- [Listes](#)
- [Membres](#)
- [Détails ouverts](#)
- [Segments](#)
- [Boutiques](#)
- [Désabonné](#)

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Automatisation	Oui	Oui	Oui	Oui	Oui
Campagnes	Non	Non	Non	Non	Non
Listes	Oui	Oui	Non	Oui	Oui
Signale un abus	Non	Oui	Non	Oui	Oui
Rapports ouverts	Non	Oui	Non	Oui	Oui
Cliquez sur les rapports	Oui	Oui	Non	Oui	Oui
Désabonnement des rapports	Non	Oui	Non	Oui	Oui
Segment	Non	Oui	Non	Oui	Oui
Membres du segment	Oui	Oui	Non	Oui	Non
Boutiques	Oui	Oui	Oui	Oui	Non

Exemple

```
mailchimp_read = glueContext.create_dynamic_frame.from_options(
    connection_type="mailchimp",
    connection_options={
        "connectionName": "connectionName",
```

```
"ENTITY_NAME": "stores",  
"INSTANCE_URL": "https://us14.api.mailchimp.com",  
  "API_VERSION": "3.0"  
})
```

Détails de l'entité et du champ Mailchimp

- [Signalements d'abus](#)
- [Automation](#)
- [Campagnes](#)
- [Détails du clic](#)
- [Listes](#)
- [Membres](#)
- [Détails ouverts](#)
- [Segments](#)
- [Boutiques](#)
- [Désabonné](#)

Requêtes de partitionnement

Vous pouvez fournir les options supplémentaires de Spark

PARTITION_FIELD, LOWER_BOUND, UPPER_BOUND, et NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- PARTITION_FIELD: le nom du champ à utiliser pour partitionner la requête.
- LOWER_BOUND: une valeur inférieure inclusive du champ de partition choisi.

Pour le DateTime champ, nous acceptons la valeur au format ISO.

Exemple de valeur valide :

```
"2024-07-01T00:00:00.000Z"
```

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: le nombre de partitions.

Le tableau suivant décrit les détails relatifs à la prise en charge des champs de partitionnement des entités :

Nom de l'entité	Champs de partitionnement	Type de données

Exemple :

```
read_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="mailchimp",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "automations",  
        "API_VERSION": "3.0",  
        "INSTANCE_URL": "https://us14.api.mailchimp.com",  
        "PARTITION_FIELD": "create_time",  
        "LOWER_BOUND": "2024-02-05T14:09:30.115Z",  
        "UPPER_BOUND": "2024-06-07T13:30:00.134Z",  
        "NUM_PARTITIONS": "3"  
    }  
)
```

Options de connexion Mailchimp

Les options de connexion pour Mailchimp sont les suivantes :

- **ENTITY_NAME**(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Mailchimp.
- **INSTANCE_URL**(String) - (Obligatoire) Une URL d'instance Mailchimp valide.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Mailchimp Engage Rest que vous souhaitez utiliser. Par exemple : 3.0.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.

- `FILTER_PREDICATE(String)` - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- `QUERY(String)` - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- `PARTITION_FIELD(String)` - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- `LOWER_BOUND(String)` - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- `UPPER_BOUND(String)` - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS(Entier)` - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Création d'un compte Mailchimp

1. Accédez à la [page de connexion de Mailchimp](#), entrez votre adresse e-mail et votre mot de passe, puis choisissez S'inscrire.
2. Ouvrez l'e-mail de confirmation envoyé par Mailchimp, puis cliquez sur le lien de confirmation pour vérifier votre compte.

Note

Le délai de réception de l'e-mail d'activation peut varier. Si vous n'avez pas reçu l'e-mail d'activation, vérifiez votre dossier de courrier indésirable et lisez nos conseils de résolution des problèmes liés à l'e-mail d'activation. [Mailchimp bloque les inscriptions provenant d'adresses e-mail basées sur des rôles, telles que `admin@pottedplanter.com` ou `security@example.com`.](#)

La première fois que vous vous connectez à votre compte, Mailchimp vous demande les informations requises. Mailchimp utilise ces informations pour s'assurer que votre compte est conforme à ses conditions d'utilisation et pour fournir des conseils adaptés à vos besoins et à ceux de votre entreprise.

3. Entrez vos informations, suivez les instructions pour terminer le processus d'activation et lancez-vous dans votre nouveau compte Mailchimp.

Enregistrement d'une **OAuth2.0** application

1. Accédez à la [page de connexion de Mailchimp](#), entrez votre adresse e-mail et votre mot de passe, puis choisissez Se connecter.
2. Sélectionnez l'icône Utilisateur dans le coin supérieur droit, puis choisissez Compte et facturation dans le menu déroulant.
3. Sélectionnez Extras, puis sélectionnez Applications enregistrées dans le menu déroulant.
4. Localisez et choisissez Enregistrer une application.
5. Entrez les informations suivantes :
 - Nom de l'application : nom de l'application.
 - Entreprise/organisation — Nom de votre entreprise ou organisation.
 - Site Web de l'application — Site Web de l'application.
 - URI de redirection — Un modèle d'URI de redirection est un chemin d'URI (ou une liste de chemins séparés par des virgules) vers lequel Mailchimp peut rediriger (si demandé) une fois le flux de connexion terminé. Par exemple, `https://ap-southeast-2\\.console\\.aws\\.amazon\\.com`
6. Sélectionnez Create (Créer).
7. L'ID client et le secret du client seront désormais visibles. Copiez-les et enregistrez-les dans un endroit sûr. Choisissez ensuite Terminé.

Note

Vos chaînes d'ID client et de secret client sont des informations d'identification utilisées pour établir une connexion avec ce connecteur lors de l'utilisation de AppFlow ou AWS Glue.

Génération d'une clé d'API

1. Accédez à la [page de connexion de Mailchimp](#), entrez votre adresse e-mail et votre mot de passe, puis choisissez Se connecter.
2. Sélectionnez l'icône Utilisateur dans le coin supérieur droit, puis choisissez Compte et facturation dans le menu déroulant.
3. Sélectionnez Extras et choisissez les clés d'API dans le menu déroulant.

4. Choisissez Créer une clé.
5. Entrez le nom de la clé et choisissez Generate Key.

La page suivante affiche la clé d'API générée.

6. Copiez votre clé, stockez-la en toute sécurité et choisissez OK.

Limites

Les limites du connecteur Mailchimp sont les suivantes :

- La filtration n'est prise en charge que par les Segments entités Campaigns Automations ListsOpen Details,Members,,, et.
- Lorsque vous utilisez un filtre sur un champ de DateTime type de données, vous devez transmettre des valeurs au format suivant : yyyy-mm-ddThh:MM:ssZ

Connexion à Microsoft Teams

Microsoft Teams est un espace de travail collaboratif au sein de Microsoft 365 qui sert de plaque tournante pour les conversations sur le lieu de travail, le travail d'équipe collaboratif, les chats vidéo et le partage de documents, le tout conçu pour améliorer la productivité des employés dans une suite unifiée d'outils.

Rubriques

- [AWS Glue support pour Microsoft Teams](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Microsoft Teams](#)
- [Configuration des connexions Microsoft Teams](#)
- [Lecture à partir d'entités Microsoft Teams](#)
- [Référence des options de connexion Microsoft Teams](#)
- [Limites](#)
- [Créez un nouveau compte Microsoft Teams :](#)

AWS Glue support pour Microsoft Teams

AWS Glue prend en charge Microsoft Teams comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Microsoft Teams.

Soutenu en tant que cible ?

Non

Versions de l'API Microsoft Teams prises en charge

v1. Pour la prise en charge des entités par version spécifique, voir Entités prises en charge pour la source.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Vous pouvez également utiliser les politiques IAM gérées suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Microsoft Teams

Avant de pouvoir AWS Glue transférer des données depuis Microsoft Teams, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous disposez d'un compte de développeur Microsoft Teams avec e-mail et mot de passe. Pour de plus amples informations, veuillez consulter [Créez un nouveau compte Microsoft Teams](#) .
- Vous devez avoir configuré une OAuth2 application dans votre compte Microsoft qui fournit l'ID client et les informations d'identification secrètes qui permettent d' AWS Glue accéder à vos données en toute sécurité lorsqu'elle effectue des appels authentifiés vers votre compte. Pour de plus amples informations, veuillez consulter [Créez un nouveau compte Microsoft Teams](#) .

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Microsoft Teams. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Microsoft Teams.

Configuration des connexions Microsoft Teams

Microsoft Teams prend en charge les deux types de mécanismes d'authentification suivants :

1. OAuth Auth : Microsoft Teams prend en charge le type de subvention AUTHORIZATION_CODE pour. OAuth2
 - Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. L'utilisateur qui crée une connexion peut par défaut s'appuyer sur une application connectée AWS Glue détenue par lui, dans laquelle il n'a pas besoin de fournir d'informations OAuth connexes, à l'exception de l'URL de l'instance Microsoft Teams. La AWS Glue console redirige l'utilisateur vers Microsoft Teams où il doit se connecter et accorder AWS Glue les autorisations demandées pour accéder à son instance Microsoft Teams.

- Les utilisateurs peuvent choisir de créer leur propre application connectée dans Microsoft Teams et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Microsoft Teams pour se connecter et autoriser AWS Glue l'accès à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est actif pendant une heure et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- Pour consulter la documentation publique de Microsoft Teams sur la création d'une application connectée pour le OAuth flux de code d'autorisation, voir | Microsoft Learn. [Enregistrez une application auprès de la plateforme d'identité Microsoft, Microsoft Graph.](#)

Pour configurer une connexion Microsoft Teams, procédez comme suit :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes. Il est nécessaire de créer un secret pour chaque connexion dans AWS Glue.
 - a. Pour l' OAuth authentication :
 - Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec la clé `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
2. Dans AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 - a. Sous Connexions de données, choisissez Créer une connexion.
 - b. Lorsque vous sélectionnez une source de données, sélectionnez Microsoft Teams.
 - c. Indiquez votre identifiant de locataire Microsoft Teams.
 - d. Sélectionnez le rôle IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
```

```

        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
    ],
    "Resource": "*"
}
]
}

```

- e. Fournir une application client gérée par l'utilisateur ClientId de l'application Microsoft Teams.
 - f. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - g. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire secretName. Choisissez Suivant.
 4. Dans la configuration de votre AWS Glue tâche, fournissez connectionName une connexion réseau supplémentaire.

Lecture à partir d'entités Microsoft Teams

Prérequis

- Un objet Microsoft Teams dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet, tel que team ou channel-message. Le tableau suivant indique les entités prises en charge.

Entités prises en charge pour Source

Toutes les entités sont prises en charge avec la version 1.0 de l'API.

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Equipes	Non	Non	Non	Oui	Non
Membres de l'équipe	Oui	Oui	Non	Oui	Oui

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Groups	Oui	Oui	Oui	Oui	Oui
Membres du groupe	Oui	Oui	Non	Oui	Non
Canaux	Oui	Non	Non	Oui	Oui
Messages du canal	Non	Oui	Non	Oui	Non
Réponses aux messages de la chaîne	Non	Oui	Non	Oui	Non
Onglets des chaînes	Oui	Non	Non	Oui	Non
Conversations	Oui	Oui	Oui	Oui	Oui
Événements du calendrier	Oui	Oui	Oui	Oui	Oui

Exemple

```
MicrosoftTeams_read = glueContext.create_dynamic_frame.from_options(
    connection_type="MicrosoftTeams",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "company",
        "API_VERSION": "v1.0"
    }
)
```

Détails des entités et des champs Microsoft Teams

Liste des entités :

- Équipe : <https://docs.microsoft.com/en-us/graph/api/user-list-joinedteams?view=graph-rest-1.0>
- Membre de l'équipe : [-list-members ? https://docs.microsoft.com/en-us/graph/api/team view=graph-rest-1.0](https://docs.microsoft.com/en-us/graph/api/team-view=graph-rest-1.0)
- Groupe : <https://docs.microsoft.com/en-us/graph/api/group-list?view=graph-rest-1.0>
- Membre du groupe : [-list-members ? https://docs.microsoft.com/en-us/graph/api/group view=graph-rest-1.0](https://docs.microsoft.com/en-us/graph/api/group-view=graph-rest-1.0)
- Chaîne : <https://docs.microsoft.com/en-us/graph/api/channel-list?view=graph-rest-1.0>
- Message du canal : [-list-messages ? https://docs.microsoft.com/en-us/graph/api/channel view=graph-rest-1.0](https://docs.microsoft.com/en-us/graph/api/channel-view=graph-rest-1.0)
- Channel-Message-Reply : [-list-replies ? https://docs.microsoft.com/en-us/graph/api/chatmessage view=graph-rest-1.0](https://docs.microsoft.com/en-us/graph/api/chatmessage-view=graph-rest-1.0)
- Channel-Tab : [https://docs.microsoft.com/en-us/graph/api/channel -list-tabs?view=graph-rest-1.0](https://docs.microsoft.com/en-us/graph/api/channel-list-tabs?view=graph-rest-1.0)
- Chat : <https://docs.microsoft.com/en-us/graph/api/chat-list?view=graph-rest-1.0>
- Calendrier-événement : [-liste-événements ? https://docs.microsoft.com/en-us/graph/api/group view=graph-rest-1.0](https://docs.microsoft.com/en-us/graph/api/group-view=graph-rest-1.0)

Requêtes de partitionnement

Des options Spark supplémentaires `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, `NUM_PARTITIONS` peuvent être fournies si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur inférieure inclusive du champ de partition choisi.

Pour la date, nous acceptons le format de date Spark utilisé dans les requêtes SQL Spark.
Exemple de valeurs valides : "2024-02-06".

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`: nombre de partitions.

Les détails du support des champs de partitionnement par entité sont présentés dans le tableau ci-dessous :

Nom de l'entité	Champs de partitionnement	Type de données
Membres de l'équipe	visibleHistoryStartDateTime	DateTime
Groups	createdDateTime	DateTime
Canaux	createdDateTime	DateTime
Conversations	createdDateTime, lastModifiedDate Heure	DateTime
Événements du calendrier	createdDateTime, lastModifiedDate Heure, Début initial	DateTime

Exemple

```
microsoftteams_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="MicrosoftTeams",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "group",  
        "API_VERSION": "v1.0",  
        "PARTITION_FIELD": "createdDateTime"  
        "LOWER_BOUND": "2022-07-13T07:55:27.065Z"  
        "UPPER_BOUND": "2022-08-12T07:55:27.065Z"  
        "NUM_PARTITIONS": "2"  
    }  
)
```

Référence des options de connexion Microsoft Teams

Les options de connexion pour Microsoft Teams sont les suivantes :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Microsoft Teams.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Microsoft Teams Rest que vous souhaitez utiliser. Exemple : v1.0.

- `SELECTED_FIELDS(Liste<String>)` - Par défaut : vide (`SELECT *`). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- `FILTER_PREDICATE(String)` - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- `QUERY(String)` - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- `PARTITION_FIELD(String)` - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- `LOWER_BOUND(String)` - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- `UPPER_BOUND(String)` - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS(Entier)` - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Limites

Les limites du connecteur Microsoft Teams sont les suivantes :

- L'API Microsoft Teams renvoie un nombre d'enregistrements inférieur à celui spécifié pour les entités Chat et Team Member. Ce problème a été signalé au Support Microsoft Teams et fait actuellement l'objet d'une enquête.

Créez un nouveau compte Microsoft Teams :

1. Accédez à la page d'accueil de Microsoft Teams, <https://account.microsoft.com/account/> puis choisissez Se connecter.
2. Choisissez Create one ! .
3. Entrez les informations requises pour la création du compte et créez un nouveau compte.
4. Accédez au site Web de Microsoft Teams à l'adresse <https://www.microsoft.com/en-in/microsoft-teams/log-in>.
5. Inscrivez-vous à l'aide du compte Microsoft que vous venez de créer.
6. Une fois votre inscription réussie sur Teams, accédez à <https://account.microsoft.com/services>.
7. Choisissez Essayer Microsoft 365.
8. Activez l'un des abonnements Microsoft 365 ou Microsoft Teams ci-dessous pour accéder à toutes les fonctionnalités requises du connecteur Microsoft Teams :

- Microsoft Teams Essentials
- Microsoft 365 pour entreprises
- Microsoft 365 Business Basic
- Microsoft 365 Business Standard
- Microsoft 365 Business Premium

Créez une application client gérée :

1. Pour créer une application gérée, vous devez enregistrer une nouvelle OAuth application sur Microsoft Entra (anciennement Azure Active Directory) :
2. Connectez-vous au [centre d'administration Microsoft Entra](#).
3. Si vous avez accès à plusieurs locataires, utilisez l'icône Paramètres dans le menu supérieur pour passer au client dans lequel vous souhaitez enregistrer l'application depuis le menu Répertoires et abonnements.
4. Accédez à Identité > Applications > Enregistrements d'applications et sélectionnez Nouvel enregistrement.
5. Entrez un nom d'affichage pour votre application.
6. Spécifiez qui peut utiliser l'application dans la section Types de comptes pris en charge. Pour que cette application soit globale, sélectionnez « Comptes dans n'importe quel répertoire d'organisation » ou « Comptes dans n'importe quel annuaire d'organisation et comptes Microsoft personnels ».
7. Entrez l'URI de redirection `https://{region}.console.aws.amazon.com/appflow/oauth`. Par exemple, pour leus-west-2 region, ajoutez `https://us-west-2.console.aws.amazon.com/appflow/oauth`. Vous pouvez en ajouter plusieurs URLs pour les différentes régions que vous souhaitez utiliser.
8. Enregistrez l'application.
9. Notez l'ID client pour une utilisation future.
10. Choisissez Ajouter un certificat ou un secret dans la section Essentiels.
11. Choisissez Nouveau secret client.
12. Entrez la description et la durée d'expiration.
13. Copiez et enregistrez le secret du client pour une utilisation future.
14. Dans la liste du menu de gauche, sélectionnez les autorisations d'API.

15. Choisissez Ajouter une autorisation.
16. Sélectionnez « Microsoft Graph ».
17. Sélectionnez « Autorisations déléguées ».
18. Vérifiez toutes les autorisations suivantes :

- Utilisateur.Read
- Accès hors ligne
- Utilisateur.Lisez.Tout
- Utilisateur. ReadWrite.Tout
- TeamsTab.ReadWriteForTeam
- TeamsTab.ReadWriteForChat
- TeamsTab. ReadWrite.Tout
- TeamsTab. Lisez. Tout
- TeamSettings. ReadWrite.Tout
- TeamSettings. Lisez. Tout
- TeamMember. ReadWrite.Tout
- TeamMember. Lisez. Tout
- L'équipe. ReadBasic.Tout
- GroupMember. ReadWrite.Tout
- GroupMember. Lisez. Tout
- Groupe. ReadWrite.Tout
- Grouper. Tout lire
- Annuaire. ReadWrite.Tout
- Répertoire.Tout lire
- Annuaire. AccessAsUser.Tout
- Discuter. ReadWrite
- Discuter. ReadBasic
- Discuter. Lire
- ChannelSettings. ReadWrite.Tout
- ChannelSettings. Lisez. Tout
- ChannelMessage. Lisez. Tout

- Canal. ReadBasic.Tout

19. Choisissez Add permissions (Ajouter des autorisations). Votre application est maintenant correctement configurée. Vous pouvez utiliser l'ID client et le secret du client pour créer une nouvelle connexion. Pour plus d'informations, voir <https://learn.microsoft.com/en-us/graph/auth-register-app-v2>.

Connexion à Mixpanel

Mixpanel est une puissante plateforme d'analyse en temps réel qui aide les entreprises à mesurer et à optimiser l'engagement des utilisateurs. Mixpanel est une application utilisée pour suivre le comportement des clients. Il vous permet de suivre la manière dont les utilisateurs interagissent avec votre produit et d'analyser ces données à l'aide de rapports interactifs qui vous permettent de consulter et de visualiser les résultats en quelques clics. En tant qu'utilisateur de Mixpanel, vous pouvez vous connecter AWS Glue à votre compte Mixpanel. Vous pouvez ensuite utiliser Mixpanel comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre Mixpanel et AWS des services ou d'autres applications prises en charge.

Rubriques

- [AWS Glue support pour Mixpanel](#)
- [Politiques contenant les opérations d'API pour la création et l'utilisation de connexions](#)
- [Configuration de Mixpanel](#)
- [Configuration des connexions Mixpanel](#)
- [Lecture à partir d'entités Mixpanel](#)
- [Options de connexion au mixpanel](#)
- [Création d'un compte Mixpanel et configuration de l'application cliente](#)
- [Limites](#)

AWS Glue support pour Mixpanel

AWS Glue prend en charge Mixpanel comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Mixpanel.

Soutenu en tant que cible ?

Non

Versions de l'API Mixpanel prises en charge

2.0

Politiques contenant les opérations d'API pour la création et l'utilisation de connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode précédente, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la

convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Mixpanel

Avant de pouvoir AWS Glue effectuer un transfert depuis Mixpanel, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous avez un compte Mixpanel. Pour plus d'informations sur la création d'un compte, consultez [Création d'un compte Mixpanel](#).
- Votre compte Mixpanel est activé pour accéder à l'API. L'accès aux API est activé par défaut pour les éditions Enterprise, Unlimited, Developer et Performance.

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Mixpanel. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Mixpanel.

Configuration des connexions Mixpanel

Mixpanel prend en charge le nom d'utilisateur et le mot de passe pour BasicAuth. L'authentification de base est une méthode d'authentification simple dans laquelle les clients fournissent des informations d'identification directement pour accéder aux ressources protégées. AWS Glue est capable d'utiliser le nom d'utilisateur et le mot de passe pour authentifier APIs Mixpanel.

Pour consulter la documentation publique de Mixpanel sur le BasicAuth flux, consultez la section [Mixpanel Service Accounts](#).

Pour configurer une connexion Mixpanel :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - Pour l'authentification de base, Secret doit contenir le Consumer Secret de l'application connectée avec USERNAME et PASSWORD comme clé.

Note

Il est indispensable de créer un secret par connexion AWS Glue.

2. Dans le AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Mixpanel.
 - b. Indiquez `INSTANCE_URL` le Mixpanel auquel vous souhaitez vous connecter.
 - c. Sélectionnez le rôle IAM pour lequel AWS Glue vous pouvez assumer les actions suivantes et qui est autorisé à les exécuter :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez Options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture à partir d'entités Mixpanel

Prérequis

Vous devez disposer d'un objet Mixpanel, tel que `FunnelRetention`, ou `Retention Funnel`, à partir duquel vous souhaitez lire des données. En outre, vous devez connaître le nom de l'objet.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Entonnoirs	Oui	Non	Non	Oui	Non
Retention	Oui	Non	Non	Oui	Non
Segmentation	Oui	Non	Non	Oui	Non
Somme de segmentation	Oui	Non	Non	Oui	Non
Moyenne de segmentation	Oui	Non	Non	Oui	Non
Cohortes	Oui	Non	Non	Oui	Non
Engagez-vous	Non	Oui	Non	Oui	Non
Événements	Oui	Non	Non	Oui	Non
Événements Top	Oui	Non	Non	Oui	Non
Noms des événements	Oui	Non	Non	Oui	Non
Propriétés des événements	Oui	Non	Non	Oui	Non
Propriétés des événements Top	Oui	Non	Non	Oui	Non
Valeurs des propriétés	Oui	Non	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
s des événements					
Annotations	Oui	Non	Non	Oui	Non
Activité liée à un événement de profil	Oui	Non	Non	Oui	Non

Exemple

```
mixpanel_read = glueContext.create_dynamic_frame.from_options(
    connection_type="mixpanel",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "/cohorts/list?project_id=2603353",
        "API_VERSION": "2.0",
        "INSTANCE_URL": "https://www.mixpanel.com/api/app/me"
    }
)
```

Détails de l'entité et du champ Mixpanel

Entité	Champ	Type de données	Opérateurs pris en charge
Funnel (Synthèse)	identifiant de l'entonnoir	Entier	'='
	identifiant de l'espace de travail	Entier	'='
	à partir de la date	Date	'='
	à ce jour	Date	'='

Entité	Champ	Type de données	Opérateurs pris en charge
	longueur	Entier	'=
	unité_de longueur	Chaîne	'=
	interval	Entier	'=
	unité	Chaîne	'=
	limite	Entier	'=
	data	Struct	
	méta	Struct	
Retention	identifiant de l'espace de travail	Entier	'=
	unité	Chaîne	'=
	unité de dépendance	Chaîne	'=
	à partir de la date	Date	'=
	à ce jour	Date	'=
	event	Chaîne	'=
	limite	Entier	'=
Segmentation	data	Struct	
	identifiant de l'espace de travail	Entier	'=
	event	Chaîne	'=
	à partir de la date	Date	'=
	à ce jour	Date	'=

Entité	Champ	Type de données	Opérateurs pris en charge
	unité	Chaîne	'=
	interval	Entier	'=
	limite	Entier	'=
	type	Chaîne	'=
	série	Liste	
	values	Struct	
	data	Struct	
Segmentation numérique	identifiant de l'espace de travail	Entier	'=
	event	Chaîne	'=
	on	Chaîne	'=
	à partir de la date	Date	'=
	à ce jour	Date	'=
	unité	Chaîne	'=
	type	Chaîne	'=
	série	Liste	
	values	Struct	
Somme de segmentation	identifiant de l'espace de travail	Entier	'=
	event	Chaîne	'=
	on	Chaîne	'=

Entité	Champ	Type de données	Opérateurs pris en charge
	à partir de la date	Date	'=
	à ce jour	Date	'=
	unité	Chaîne	'=
	métadonnées	Struct	
	results	Struct	
Moyenne de segmentation	identifiant de l'espace de travail	Entier	'=
	event	Chaîne	'=
	on	Chaîne	'=
	à partir de la date	Date	'=
	à ce jour	Date	'=
	unité	Chaîne	'=
	métadonnées	Struct	
	results	Struct	
Cohortes	count	Entier	
	est visible	Entier	
	description	Chaîne	
	créé	DateTime	
	identifiant_projet	Entier	
	id	BigInteger	

Entité	Champ	Type de données	Opérateurs pris en charge
	name	Chaîne	
	identifiant_groupe de données	Chaîne	
Engagez-vous	identifiant_distinct	Chaîne	
		propriétés	Struct
Événement	espace de travail	Entier	'=
	event	Chaîne	'=
	type	Chaîne	'=
	unité	Chaîne	'=
	interval	Entier	'=
	à partir de la date	Date	'=
	à ce jour	Date	'=
	série	Liste	
	values	Struct	
Événements Top	type	Chaîne	'=
	identifiant de l'espace de travail	Entier	'=
	limite	Entier	'=
	amount	Entier	
	event	Chaîne	
	pourcent_variation	Float	

Entité	Champ	Type de données	Opérateurs pris en charge
Nom de l'événement	data	Liste	
	identifiant de l'espace de travail	Entier	'='
	type	Chaîne	'='
	limite	Entier	'='
Propriétés d'un événement	identifiant de l'espace de travail	Entier	'='
	event	Chaîne	'='
	name	Chaîne	'='
	type	Chaîne	'='
	unité	Chaîne	'='
	interval	Entier	'='
	à partir de la date	Date	'='
	à ce jour	Date	'='
	limite	Entier	'='
	data	Struct	
	série	Liste	
	values	Struct	
Propriétés de l'événement Top	identifiant de l'espace de travail	Entier	'='
	event	Chaîne	'='

Entité	Champ	Type de données	Opérateurs pris en charge
Valeur des propriétés de l'événement	limite	Entier	'='
	data	Struct	
	identifiant de l'espace de travail	Entier	'='
	event	Chaîne	'='
	limite	Entier	'='
	name	Chaîne	'='
	data	Liste	
Annotation	identifiant de l'espace de travail	Entier	
	date	DateTime	
	identifiant_projet	Entier	
	id	BigInteger	
	description	Chaîne	
	à partir de la date	Date	BETWEEN
Activité liée à un événement de profil	identifiant de l'espace de travail	Entier	'='
	identifiant_distincts	Chaîne	'='
	à partir de la date	Date	'='
	à ce jour	Date	'='
	event	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	propriétés	Struct	

Options de connexion au mixpanel

Les options de connexion pour Mixpanel sont les suivantes :

- **ENTITY_NAME**(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Mixpanel.
- **API_VERSION**(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Rest de Mixpanel que vous souhaitez utiliser. Par exemple : v2.0.
- **SELECTED_FIELDS**(Liste<String>) — Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) — Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) — Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

Création d'un compte Mixpanel et configuration de l'application cliente

Création d'un compte Mixpanel

1. Accédez à la [page d'accueil de Mixpanel/](#).
2. Sur la page d'accueil de Mixpanel, choisissez S'inscrire dans le coin supérieur droit de la page.
3. Sur la page Commençons, effectuez les actions suivantes :
 - Entrez votre adresse e-mail dans le champ prévu à cet effet.
 - Cochez la case requise pour accepter les conditions.
 - Choisissez Get Started pour continuer.

Une fois l'opération terminée, vous recevrez un e-mail de vérification.

4. Vérifiez la présence d'un message de vérification dans votre boîte de réception, ouvrez l'e-mail et suivez les instructions pour vérifier votre adresse e-mail.

5. Sur la page de vérification, choisissez Vérifier l'adresse e-mail pour terminer la vérification de votre adresse e-mail.
6. Sur la page Nommez votre organisation, entrez le nom de votre organisation et choisissez Suivant.
7. Sur la page Votre premier projet, entrez les détails de votre projet et choisissez Créer.
8. Sur la page suivante, choisissez Let's get Started pour terminer la création de votre compte.

Connexion à un compte Mixpanel

1. Accédez à la [page de connexion de Mixpanel/](#).
2. Entrez votre adresse e-mail et choisissez Continuer.
3. Vérifiez la présence d'un message de vérification dans votre boîte de réception, ouvrez l'e-mail et suivez les instructions pour vérifier votre adresse e-mail.
4. Sur la page suivante, cliquez sur le bouton Se connecter pour vous connecter à votre compte.

Acheter un plan Mixpanel

1. Sur la page Mixpanel, sélectionnez l'icône Paramètres située dans le coin supérieur droit de la page.
2. Dans la liste des options, sélectionnez Détails du plan et facturation.
3. Sur la page Détails du plan et facturation, sélectionnez Mettre à niveau ou Modifier.
4. Sur la page suivante, sélectionnez le plan que vous souhaitez acheter.

Ceci termine le processus de création de compte et d'achat du plan.

Création d'un nom d'utilisateur et d'un secret client (pour enregistrer votre application)

1. Sur la page Mixpanel, sélectionnez l'icône Paramètres située dans le coin supérieur droit de la page. »
2. Dans la liste des options, sélectionnez Paramètres du projet.
3. Sur la page Paramètres du projet, sélectionnez Comptes de service, puis sélectionnez Ajouter un compte de service.
4. Dans la liste déroulante des comptes de service, sélectionnez le compte de service ou entrez le nom à créer, ajoutez le rôle du projet, spécifiez les dates d'expiration et sélectionnez Ajouter.

 Important

Une fois l'étape précédente terminée, la page suivante affiche la clé secrète du compte de service. Assurez-vous de sauvegarder la clé secrète du compte de service. Vous ne pourrez plus y accéder après cette étape.

Limites

Les limites du connecteur Mixpanel sont les suivantes :

- Pour `Segmentation Numeric` l'entité, l'API Mixpanel génère une 400 (Bad Request) erreur si aucune donnée numérique n'est trouvée pour les filtres obligatoires. Nous traitons cela comme une OK réponse visant à prévenir les pannes de débit.
- Le champ interrogeable `limit` a été supprimé des entités prises en charge pour les raisons suivantes :
 - Cela provoquait des erreurs car il était interprété comme la fonctionnalité limite du SDK
 - Le filtre n'a servi à rien dans la pratique
 - Les fonctionnalités équivalentes sont désormais couvertes par l'implémentation des fonctionnalités limites
- Le partitionnement basé sur le terrain ne peut pas être pris en charge en raison de l'absence d'opérateurs requis (`>=`, `<=`, `<>`, `between`) pour le partitionnement depuis la plateforme SaaS. Bien qu'il prenne en charge l'opérateur `between`, les champs pour lesquels il prend en charge cet opérateur ne sont pas récupérables. Par conséquent, les critères de partitionnement basé sur les champs ne sont pas satisfaits.
- Comme il n'existe aucune disposition permettant d'obtenir une valeur de « décalage » pour les entités prenant en charge la pagination, il n'est pas possible de prendre en charge le partitionnement basé sur des enregistrements pour Mixpanel.
- `Cohorts` L'entité ne prend en charge que `CreatedDate/Time` le champ et il n'y a aucun champ à identifier `UpdatedDate/Time`, par conséquent, `DML_Status` ne peut pas être identifié. De plus, il n'existe aucun point de terminaison pour identifier les enregistrements supprimés. Par conséquent, le CDC ne peut pas être pris en charge.
- Pour exécuter une AWS Glue tâche pour les entités mentionnées ci-dessous, des filtres obligatoires sont requis. Reportez-vous au tableau ci-dessous pour connaître les noms des entités et les filtres requis.

Nom de l'entité et filtres requis

Nom de l'entité	Filtres obligatoires
Annotations	de_date, à_date
Cohortes	Aucun
Engagez-vous	Aucun
Événement	événement, type, unité, from_date, to_date, on
Nom des événements	type
Propriétés des événements	événement, nom, type, unité, from_date, to_date
Propriétés des événements Top	event
Valeurs des propriétés des événements	événement, nom
Top des événements	type
Entonnoirs	funnel_id, from_date, to_date
Activité liée à un événement de profil	identificateurs distincts, de_date, à_date
Retention	from_date, to_date, unité, addiction_unit
Segmentation	événement, from_date, to_date
Moyenne de segmentation	événement, from_date, to_date, le
Segmentation numérique	événement, from_date, to_date, le
Somme de segmentation	événement, from_date, to_date, le

Connexion au lundi

Monday.com est un système d'exploitation de travail polyvalent qui rationalise la gestion de projet et la collaboration en équipe. Il propose des flux de travail personnalisables, des tableaux de bord visuels et des outils d'automatisation pour améliorer la productivité. Les utilisateurs peuvent suivre les tâches, gérer les ressources et communiquer efficacement sur une plateforme intégrée.

Rubriques

- [AWS Glue support pour le lundi](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration du lundi](#)
- [Configuration des connexions du lundi](#)
- [Lecture à partir des entités du lundi](#)
- [Référence des options de connexion du lundi](#)
- [Limites](#)
- [Créez un nouveau compte Monday :](#)

AWS Glue support pour le lundi

AWS Glue prend en charge le lundi comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données à partir du lundi.

Soutenu en tant que cible ?

Non

Versions d'API Monday prises en charge

v2.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
```

```
"Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Vous pouvez également utiliser les politiques IAM gérées suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration du lundi

Avant de pouvoir transférer AWS Glue des données à partir du lundi, vous devez remplir les conditions suivantes :

Configuration requise

- Vous avez un compte développeur Monday avec e-mail et mot de passe. Pour de plus amples informations, veuillez consulter [Créez un nouveau compte Monday](#) .

- Votre compte de développeur Monday est activé pour accéder à l'API. Toute utilisation du lundi APIs est disponible sans frais supplémentaires pendant la période d'essai. Une fois la période d'essai terminée, vous devez acheter un abonnement pour créer des données et y accéder. Pour plus d'informations, consultez la [page des licences de lundi](#) pour plus de détails.

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Monday. Pour les connexions classiques, vous n'avez rien d'autre à faire le lundi.

Configuration des connexions du lundi

Monday prend en charge les deux types de mécanismes d'authentification suivants :

1. OAuth Auth : Monday prend en charge le type de subvention AUTHORIZATION_CODE pour OAuth2
 - Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. L'utilisateur qui crée une connexion peut par défaut s'appuyer sur une application connectée AWS Glue détenue par lui, dans laquelle il n'a pas besoin de fournir d'informations OAuth connexes, à l'exception de l'URL de l'instance du lundi. La AWS Glue console redirigera l'utilisateur vers Monday, où il devra se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Monday.
 - Les utilisateurs doivent choisir de créer leur propre application connectée le lundi et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers le lundi pour se connecter et autoriser AWS Glue l'accès à leurs ressources.
 - Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est actif pendant une heure et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
 - Pour plus d'informations, consultez [la documentation sur la création d'une application connectée pour le flux AUTHORIZATION_CODE OAuth](#).
2. Authentification personnalisée :
 - Pour consulter la documentation publique du lundi sur la génération des clés d'API requises pour une autorisation personnalisée, voir <https://developer.monday.com/api-reference/api-token-permissionsdocs/authentication#>.

Pour configurer une connexion le lundi :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes. Il est nécessaire de créer un secret pour chaque connexion dans AWS Glue.
 - a. Pour l' OAuth authentication :
 - Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec la clé `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
 - b. Pour une authentication personnalisée :
 - Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec `personalAccessToken` comme clé.
2. Dans AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 - a. Sous Connexions de données, choisissez Créer une connexion.
 - b. Lorsque vous sélectionnez une source de données, sélectionnez Lundi.
 - c. Indiquez l'URL de votre instance du lundi.
 - d. Sélectionnez le rôle IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour celles-ci :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- e. Sélectionnez le type d'authentification pour vous connecter à Monday

- Pour OAuth l'authentification : indiquez l'URL du jeton et l'application client gérée par l'utilisateur ClientId du lundi auquel vous souhaitez vous connecter.
 - Pour une authentification personnalisée : sélectionnez le type d'authentification CUSTOM pour vous connecter à Monday.
- f. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
- g. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName. Choisissez Suivant.
4. Dans la configuration de votre AWS Glue tâche, fournissez connectionName une connexion réseau supplémentaire.

Lecture à partir des entités du lundi

Prérequis

- Un objet du lundi dont vous aimeriez lire un extrait. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge pour Source

Liste des entités :

- Compte : <https://developer.monday.com/api-reference/docs/account #queries>
- Forum : <https://developer.monday.com/api-reference/docs/boards #queries>
- Colonne : <https://developer.monday.com/api-reference/docs/columns #queries>
- Documents : <https://developer.monday.com/api-reference/docs/docs #queries>
- Bloc de documents : <https://developer.monday.com/api-reference/docs/blocks #queries>
- Fichiers : <https://developer.monday.com/api-reference/docs/files #queries>
- Dossiers : <https://developer.monday.com/api-reference/docs/folders #queries>
- Groupes : <https://developer.monday.com/api-reference/docs/groups #queries>
- Numéro d'objet : <https://developer.monday.com/api-reference/docs/items #queries>
- Sous-éléments : <https://developer.monday.com/api-reference/docs/subitems #queries>
- Mots clés : <https://developer.monday.com/api-reference/docs/tags-queries #queries>

- Équipes : <https://developer.monday.com/api-reference/docs/teams> #queries
- Mises à jour : <https://developer.monday.com/api-reference/docs/updates> #queries
- Utilisateurs : <https://developer.monday.com/api-reference/docs/users> #queries
- Espaces de travail : <https://developer.monday.com/api-reference/docs/espaces> de travail #queries

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Compte	Non	Non	Non	Oui	Non
Planches	Oui	Oui	Non	Oui	Non
Columns	Non	Non	Non	Oui	Non
Docs	Oui	Oui	Non	Oui	Non
Blocs de documents	Non	Oui	Non	Oui	Non
Dépôt de	Oui	Non	Non	Oui	Non
Groups	Non	Non	Non	Oui	Non
Élément	Oui	Oui	Non	Oui	Non
Sous-éléments	Non	Non	Non	Oui	Non
Balises	Oui	Non	Non	Oui	Oui
Equipes	Oui	Non	Non	Oui	Non
Mises à jour	Non	Oui	Non	Oui	Non
Users	Oui	Oui	Non	Oui	Non
Espaces de travail	Oui	Oui	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Dossiers	Oui	Oui	Non	Oui	Non

Exemple

```
monday_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="monday",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "account",  
        "API_VERSION": "v2"  
    }  
)
```

Référence des options de connexion du lundi

Les options de connexion pour le lundi sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet pour le lundi.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Monday Rest que vous souhaitez utiliser. Exemple : v2.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

Limites

Les limites du connecteur Monday sont les suivantes :

- La réponse dynamique aux métadonnées présente certains conflits avec la documentation, comme indiqué ci-dessous :

- L'entité Group, Column prend en charge les opérations de filtrage, mais elle n'est pas présente dans le point de terminaison des métadonnées dynamiques, elle est donc conservée en tant qu'entité non filtrable.
- Le point de terminaison dynamique comprend environ 15 000 lignes et renvoie les métadonnées de toutes les entités en une seule réponse. De ce fait, le chargement des champs prend en moyenne 10 secondes, ce qui nécessiterait un certain temps supplémentaire lors de l'exécution d'une tâche.
- Consultez le tableau ci-dessous pour connaître la limite tarifaire du lundi. La taille importante des données de réponse de l'entité dynamique entraîne un retard notable, les champs nécessitant en moyenne 10 secondes pour se charger.

Limite de complexité	5 000 000 (5 millions) points de complexité
Limite d'appels quotidiens	10 000€ pour le forfait Pro
Limite de minutes	500 requêtes par minute
Limite de simultanéité	100 demandes simultanées maximum pour le plan Pro

Créez un nouveau compte Monday :

1. Accédez à la page d'accueil de Monday, <https://monday.com/> et choisissez Login.
2. Vous serez redirigé vers la page de connexion. Au bas de la page, choisissez S'inscrire.
3. Entrez votre adresse e-mail et choisissez Continuer. Vous pouvez également vous connecter avec Google.
4. Entrez les informations requises et choisissez Continuer.
5. Répondez aux questions du sondage et suivez les étapes pour terminer le processus de création de compte.

Enregistrez une OAuth application :

1. Connectez-vous à votre compte monday.com. Cliquez sur votre avatar (icône en forme d'image) dans le coin inférieur gauche de votre écran.
2. Choisissez Developer.

3. Choisissez Créer une application.
4. Complétez les champs obligatoires pour le nom et la description.
5. Accédez à la section « OAuth » présente sur le côté droit, ajoutez les portées et choisissez « Enregistrer la fonctionnalité ».
6. Accédez à l'onglet « URL de redirection » à côté du champ d'application, ajoutez l'URL de redirection et choisissez « Enregistrer la fonctionnalité ».
7. Dans l'URLonglet Redirection, indiquez l'URL de votre application. Cela devrait être `https://{region-code}.console.aws.amazon.com/appflow/ OAuth`. Par exemple, si vous utilisez, `us-east-1` vous pouvez ajouter `https://us-east-1.console.aws.amazon.com/appflow/oauth`.
8. L'application est maintenant prête à être utilisée. Vous trouverez vos informations d'identification dans la section « Informations de base ». Notez votre identifiant client et les chaînes secrètes du client. Ces chaînes sont utilisées pour établir une connexion avec cette application à l'aide d'un AppFlow connecteur.

Générez un jeton d'accès personnel :

Actuellement, monday.com ne propose que nos jetons API V2, qui sont tous des jetons personnels. Pour accéder à vos jetons d'API, vous pouvez utiliser l'une des deux méthodes suivantes en fonction de votre niveau d'utilisateur. Les utilisateurs administrateurs peuvent utiliser les deux méthodes pour acquérir leurs jetons d'API. Les utilisateurs membres peuvent accéder à leurs jetons d'API depuis leurs onglets Développeur.

Administrateurs - Si vous êtes un utilisateur administrateur de votre compte monday.com, vous pouvez accéder à vos jetons d'API depuis l'onglet « Admin » en suivant les étapes suivantes :

1. Connectez-vous à votre compte monday.com. Cliquez sur votre avatar (icône en forme d'image) dans le coin inférieur gauche de votre écran.
2. Sélectionnez « Administration » dans le menu qui s'affiche (cela nécessite que vous disposiez des autorisations d'administrateur).
3. Accédez à la section « API » et générez un « jeton API V2 ». Vous pouvez copier votre jeton et l'utiliser.

Développeur : si vous êtes un utilisateur membre de votre compte monday.com, vous pouvez accéder à vos jetons d'API depuis l'onglet Développeur en suivant les étapes suivantes :

1. Connectez-vous à votre compte monday.com. Cliquez sur votre avatar (icône en forme d'image) dans le coin inférieur gauche de votre écran.
2. Sélectionnez « Développeurs » dans le menu qui s'affiche.
3. Dans le menu supérieur, choisissez le menu déroulant « Développeur ». Sélectionnez la première option dans le menu déroulant intitulé « Mes jetons d'accès ».

Connexion à MongoDB dans AWS Glue Studio

AWS Glue fournit un support intégré pour MongoDB. AWS Glue Studio fournit une interface visuelle pour se connecter à MongoDB, créer des tâches d'intégration de données et les exécuter sur AWS Glue Studio environnement d'exécution Spark sans serveur.

Rubriques

- [Création d'une connexion MongoDB](#)
- [Création d'un nœud source MongoDB](#)
- [Création d'un nœud cible MongoDB](#)
- [Options avancées](#)

Création d'une connexion MongoDB

Prérequis :

- Si votre instance MongoDB se trouve dans un Amazon VPC, configurez Amazon VPC pour permettre à votre AWS Glue tâche de communiquer avec l'instance MongoDB sans que le trafic ne transite par l'Internet public.

Dans Amazon VPC, identifiez ou créez un VPC, un sous-réseau et un groupe de sécurité qui AWS Glue seront utilisés lors de l'exécution de la tâche. En outre, vous devez vous assurer qu'Amazon VPC est configuré pour autoriser le trafic réseau entre votre instance MongoDB et cet emplacement. Selon la configuration de votre réseau, cela peut nécessiter des modifications des règles du groupe de sécurité, du réseau ACLs, des passerelles NAT et des connexions d'appairage.

Pour configurer une connexion à MongoDB :

1. Vous pouvez éventuellement créer un secret à AWS Secrets Manager l'aide de vos informations d'identification MongoDB. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.

- Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé *username* contenant la valeur. *mongodbUser*

Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé *password* contenant la valeur. *mongodbPass*

2. Dans la AWS Glue console, créez une connexion en suivant les étapes décrites dans [the section called "Ajouter une AWS Glue connexion"](#). Après avoir créé la connexion, conservez le nom de la connexion pour une utilisation future dans AWS Glue. *connectionName*

- Lorsque vous sélectionnez un type de connexion, sélectionnez MongoDB ou MongoDB Atlas.
- Lorsque vous sélectionnez une URL MongoDB ou une URL MongoDB Atlas, indiquez le nom d'hôte de votre instance MongoDB.

Une URL MongoDB est fournie au format
mongodb://mongoHost:mongoPort/mongoDBName.

Une URL MongoDB Atlas est fournie au format *mongodb*
+srv://mongoHost:mongoPort/mongoDBName.

La fourniture de la base de données par défaut pour la connexion *mongoDBName* est facultative.

- Si vous avez choisi de créer un secret Secrets Manager, choisissez le type AWS Secrets Manager d'identifiant.

Ensuite, dans AWS Secret, fournissez *secretName*.

- Si vous choisissez de fournir un nom d'utilisateur et un mot de passe, fournissez *mongodbUser* et *mongodbPass*.

3. Dans les situations suivantes, vous pouvez avoir besoin d'une configuration supplémentaire :

- Pour les instances MongoDB hébergées AWS dans un Amazon VPC

- Vous devrez fournir les informations de connexion Amazon VPC à la AWS Glue connexion qui définit vos informations d'identification de sécurité MongoDB. Lorsque vous créez ou mettez à jour votre connexion, définissez le VPC, le sous-réseau et les groupes de sécurité dans les options réseau.

Après avoir créé une connexion AWS Glue MongoDB, vous devez effectuer les étapes suivantes avant d'exécuter votre AWS Glue tâche :

- Lorsque vous travaillez avec des AWS Glue tâches dans l'éditeur visuel, vous devez fournir les informations de connexion Amazon VPC pour que votre tâche se connecte à MongoDB. Identifiez un emplacement approprié dans Amazon VPC et fournissez-le à votre connexion AWS Glue MongoDB.
- Si vous avez choisi de créer un secret Secrets Manager, accordez au rôle IAM associé à votre AWS Glue tâche l'autorisation de lecture *secretName*.

Création d'un nœud source MongoDB

Prérequis

- Une connexion AWS Glue MongoDB, comme décrit dans la section précédente, [the section called “Création d'une connexion MongoDB”](#)
- Si vous choisissez de créer un secret Secrets Manager, allouez des autorisations pour votre tâche pour lire le secret utilisé par la connexion.
- Une collection MongoDB à partir de laquelle vous souhaitez lire. Vous aurez besoin des informations d'identification pour la collection.

Une collection MongoDB est identifiée par un nom de base de données et un nom de collection, *mongodbName.mongodbCollection*

Ajout d'une source de données MongoDB

Pour ajouter un nœud Source de données – MongoDB :

1. Choisissez la connexion pour votre source de données MongoDB. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Créer une connexion MongoDB. Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion MongoDB”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Choisissez une Base de données. Saisissez *mongodbName*.
3. Choisissez une Collection. Saisissez *mongodbCollection*.
4. Choisissez votre Partitionneur, la Taille de partition (Mo) et la Clé de partition. Pour plus d'informations sur les paramètres de partition, consultez [the section called “« connectionType »: « mongodb » comme source”](#).
5. Dans les Propriétés MongoDB personnalisées, saisissez les paramètres et les valeurs nécessaires.

Création d'un nœud cible MongoDB

Prérequis

- Une connexion AWS Glue MongoDB, configurée avec un AWS Secrets Manager secret, comme décrit dans la section précédente, [the section called “Création d'une connexion MongoDB”](#)
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.
- Une table MongoDB dans laquelle vous souhaitez écrire, *tableName*

Ajout d'une cible de données MongoDB

Pour ajouter un nœud Cible de données – MongoDB :

1. Choisissez la connexion pour votre source de données MongoDB. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Créer une connexion MongoDB. Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion MongoDB”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Choisissez une Base de données. Saisissez *mongodbName*.
3. Choisissez une Collection. Saisissez *mongodbCollection*.
4. Choisissez votre Partitionneur, la Taille de partition (Mo) et la Clé de partition. Pour plus d'informations sur les paramètres de partition, consultez [the section called “« connectionType »: « mongodb » comme source”](#).

5. Choisissez Réessayer les écritures si vous le souhaitez.
6. Dans les Propriétés MongoDB personnalisées, saisissez les paramètres et les valeurs nécessaires.

Options avancées

Vous pouvez fournir des options avancées lors de la création d'un nœud MongoDB. Ces options sont les mêmes que celles disponibles lors de la programmation AWS Glue de scripts Spark.

Consultez [the section called “Connexion MongoDB”](#).

Connexion à Oracle NetSuite

Oracle NetSuite est une solution de gestion d'entreprise all-in-one dans le cloud qui aide les entreprises à fonctionner plus efficacement en automatisant les processus de base et en fournissant une visibilité en temps réel sur les performances opérationnelles et financières. Grâce à une suite unique et intégrée d'applications pour la gestion de la comptabilité, du traitement des commandes, de la gestion des stocks, de la production, de la chaîne d'approvisionnement et des opérations d'entrepôt, Oracle NetSuite donne aux entreprises une visibilité claire sur leurs données et un contrôle plus strict de leurs activités.

Rubriques

- [AWS Glue support pour Oracle NetSuite](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration d'Oracle NetSuite](#)
- [Configuration des NetSuite connexions Oracle](#)
- [Lecture à partir d' NetSuite entités Oracle](#)
- [Options de NetSuite connexion Oracle](#)
- [Limitations et remarques relatives au NetSuite connecteur Oracle](#)

AWS Glue support pour Oracle NetSuite

AWS Glue prend en charge Oracle NetSuite comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger les données d'Oracle NetSuite.

Soutenu en tant que cible ?

Non

Versions d' NetSuite API Oracle prises en charge

Les versions suivantes de NetSuite l'API Oracle sont prises en charge :

- v1

Pour la prise en charge des entités par version spécifique, voir Entités prises en charge pour la source.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources

spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration d'Oracle NetSuite

Avant de pouvoir AWS Glue transférer des données depuis Oracle NetSuite, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un NetSuite compte Oracle. Pour de plus amples informations, veuillez consulter [Création d'un NetSuite compte Oracle](#).
- Votre NetSuite compte Oracle est activé pour accéder à l'API.
- Vous avez créé une intégration d'API OAuth 2.0 dans votre compte de NetSuite développeur Oracle. Cette intégration fournit les informations d'identification du client qui AWS Glue permettent d'accéder à vos données en toute sécurité lorsqu'il effectue des appels authentifiés vers votre compte. Pour de plus amples informations, veuillez consulter [Création d'une application NetSuite client Oracle et d'informations d'identification OAuth 2.0](#).

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre NetSuite compte Oracle.

Création d'un NetSuite compte Oracle

Accédez à [Oracle NetSuite](#), puis choisissez Free Product Tour. Renseignez les informations requises pour bénéficier d'une visite guidée gratuite du produit, grâce à laquelle vous pourrez contacter un fournisseur. La procédure d'obtention d'un compte est la suivante :

- L'achat d'un NetSuite compte est effectué par l'intermédiaire d'un fournisseur, qui fournit un formulaire/un devis qui doit être légalement révisé.

- Le compte à acheter pour le NetSuite connecteur Oracle est un compte Standard Cloud Service.
- Ce compte est créé par le fournisseur et les informations d'identification temporaires sont partagées par celui-ci. Vous recevrez un e-mail de bienvenue NetSuite < billing@notification.netsuite.com > < system@sent-via.netsuite.com > contenant des informations telles que votre nom d'utilisateur et un lien pour définir votre mot de passe.
- Utilisez le lien Définissez votre mot de passe pour définir le mot de passe du nom d'utilisateur fourni par le fournisseur.

Création d'une application NetSuite client Oracle et d'informations d'identification OAuth 2.0

Pour obtenir l'ID client et le secret du client, vous devez créer une application NetSuite client Oracle :

1. Connectez-vous à votre NetSuite compte via l'[identifiant NetSuite client](#).
2. Choisissez Configuration > Entreprise > Activer les fonctionnalités.
3. Accédez à la SuiteCloudsection et cochez la case REST WEB SERVICES sous SuiteTalk (Web Services).
4. Cochez la case OAUTH 2.0 sous Gérer l'authentification. Cliquez sur Sauvegarder
5. Accédez à Configuration > Intégration > Gérer les intégrations et choisissez Nouveau pour créer une application OAuth2 .0.
6. Entrez le nom de votre choix et conservez le paramètre STATE comme Enabled.
7. Si cette case est cochée, décochez les cases TBA : FLUX D'AUTORISATION et AUTHENTIFICATION BASÉE SUR LES JETONS affichées sous Authentification basée sur les jetons.
8. Cochez les cases AUTHORIZATION CODE GRANT et PUBLIC CLIENT sous OAuth 2.0.
9. Sous Auth, notez l'ID du client et le secret du client.
- 10Entrez un URI DE REDIRECTION. Par exemple, https://us-east-1.console.aws.amazon.com/gluestudio/ oauth
- 11Cochez la case REST WEB SERVICES sous SCOPE.
- 12Cochez la case INFORMATIONS D'IDENTIFICATION DE L'UTILISATEUR sous Informations d'identification de l'utilisateur. Choisissez Save (Enregistrer).
- 13Notez le KEY/CLIENT ID and CONSUMER SECRET/CLIENT SECRET DU CONSOMMATEUR sous Informations d'identification du client. Ces valeurs ne sont affichées qu'une seule fois.
- 14Créez un rôle ADMINISTRATEUR si nécessaire en accédant à Utilisateur/Rôles > Gérer les rôles > Nouveau.

15 Lors de la création d'un rôle personnalisé, ajoutez un accès complet sous l'onglet Autorisations pour les entités/fonctionnalités suivantes :

- « Dépôt », « Articles », « Livraison des articles », « Inscription au journal », « Bon de commande », « Filiales », « Fournisseurs », « Factures », « Autorisation de retour du fournisseur », « Suivi du temps », « Paiement client », « Entrées d'enregistrement personnalisées », « Types d'enregistrements personnalisés », « Gestion des applications autorisées OAuth 2.0 », « Champs d'entité personnalisés », « Connectez-vous à l'aide de jetons d'accès OAuth 2.0 ».

Pour plus d'informations, consultez la [OAuth version 2.0](#) dans la documentation d' NetSuite Applications Suite.

Configuration des NetSuite connexions Oracle

Oracle NetSuite prend en charge le type de subvention AUTHORIZATION_CODE pour. OAuth2 Le type de subvention détermine le AWS Glue mode de communication avec Oracle NetSuite pour demander l'accès à vos données.

- Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers un serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. L'utilisateur qui crée une connexion peut par défaut s'appuyer sur une application connectée lui AWS Glue appartenant (application client AWS Glue gérée) sur laquelle il n'a pas besoin de fournir d'informations OAuth connexes, à l'exception de l'URL de son NetSuite instance Oracle. La AWS Glue console redirige l'utilisateur vers Oracle NetSuite où il doit se connecter et accorder AWS Glue les autorisations demandées pour accéder à son NetSuite instance Oracle.
- Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans Oracle NetSuite et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Oracle NetSuite pour se connecter et autoriser AWS Glue l'accès à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- Pour consulter NetSuite la documentation Oracle publique sur la création d'une application connectée pour le OAuth flux de code d'autorisation, voir [Applications publiques](#).

Pour configurer une NetSuite connexion Oracle, procédez comme suit :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir le secret du consommateur de l'application connectée avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
 - b. Remarque : Vous devez créer un secret pour votre connexion dans AWS Glue.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Oracle NetSuite.
 - b. Fournissez l' NetSuite environnement Oracle.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture à partir d' NetSuite entités Oracle

Prérequis

Un NetSuite objet Oracle dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet tel que `deposit outtimebill`. Le tableau suivant indique les entités prises en charge.

Entités prises en charge pour la source :

Entité	Peut être filtré	Supporte Order By	Limite de supports	Supporte SELECT *	Supporte le partitionnement
Dépôt	Oui	Non	Oui	Oui	Oui
Description de l'article	Oui	Non	Oui	Oui	Oui
Article d'inventaire	Oui	Non	Oui	Oui	Oui
Expédition des articles	Oui	Non	Oui	Oui	Oui
Groupe d'articles	Oui	Non	Oui	Oui	Oui
Entrée de journal	Oui	Non	Oui	Oui	Oui
Article non acheté en stock	Oui	Non	Oui	Oui	Oui
Article non revendu en stock	Oui	Non	Oui	Oui	Oui

Entité	Peut être filtré	Supporte Order By	Limite de supports	Supporte SELECT *	Supporte le partitionnement
Article en vente hors stock	Oui	Non	Oui	Oui	Oui
Bon de commande	Oui	Non	Oui	Oui	Oui
Filiale	Oui	Non	Oui	Oui	Oui
Vendor	Oui	Non	Oui	Oui	Oui
Facture du fournisseur	Oui	Non	Oui	Oui	Oui
Autorisation de retour du fournisseur	Oui	Non	Oui	Oui	Oui
Facture de temps	Oui	Non	Oui	Oui	Oui
Paiement par le client	Oui	Non	Oui	Oui	Oui
Demande d'expédition	Oui	Non	Oui	Oui	Oui

Exemple :

```

netsuiteerp_read = glueContext.create_dynamic_frame.from_options(
    connection_type="netsuiteerp",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "deposit",
        "API_VERSION": "v1"
    }
)

```

```
}  
)
```

Détails de NetSuite l'entité et du champ Oracle :

Oracle charge NetSuite dynamiquement les champs disponibles sous l'entité sélectionnée. Selon le type de données du champ, il prend en charge les opérateurs de filtre suivants.

Type de données de champ	Opérateurs de filtre pris en charge
Chaîne	COMME, =, !=
Date	ENTRE, =, <, <=, >, >=
DateTime	ENTRE, <, <=, >, >=
Numérique	=, !=, <, <=, >, >=
Booléen	=, !=

Requêtes de partitionnement

Partitionnement basé sur le terrain

Le NetSuite connecteur Oracle possède des métadonnées dynamiques afin que les champs pris en charge pour le partitionnement basé sur les champs soient choisis de manière dynamique. Le partitionnement basé sur les champs est pris en charge sur les champs de type Integer BigInteger, Date ou DateTime.

Vous pouvez fournir les options supplémentaires de Spark

PARTITION_FIELD, LOWER_BOUND, UPPER_BOUND, et NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- PARTITION_FIELD: le nom du champ à utiliser pour partitionner la requête.
- LOWER_BOUND: une valeur de limite inférieure inclusive du champ de partition choisi.

Pour le champ d'horodatage, nous acceptons le format d'horodatage Spark utilisé dans les requêtes SQL Spark.

Exemples de valeurs valides :

```
"TIMESTAMP \"1707256978123\""  
"TIMESTAMP \"1702600882\""  
"TIMESTAMP '2024-02-06T22:00:00:00.000Z'"  
"TIMESTAMP '2024-02-06T22:00:00:00Z'"  
"TIMESTAMP '2024-02-06'"
```

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: le nombre de partitions.

Exemple :

```
oracle-netsuite_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="oracle-netsuite",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "company",  
        "API_VERSION": "v3",  
        "PARTITION_FIELD": "hs_object_id"  
        "LOWER_BOUND": "50"  
        "UPPER_BOUND": "16726619290"  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Partitionnement basé sur des enregistrements

Vous pouvez fournir l'option Spark supplémentaire NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ce paramètre, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

Dans le partitionnement basé sur les enregistrements, le nombre total d'enregistrements présents est demandé à partir de NetSuite l'API Oracle, puis divisé par le NUM_PARTITIONS nombre fourni, le nombre d'enregistrements qui en résulte est ensuite extrait simultanément par chaque sous-requête.

- NUM_PARTITIONS: le nombre de partitions.

Exemple :

```
netsuiteerp_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="oracle-netsuite",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "company",  
        "API_VERSION": "v3",  
        "PARTITION_FIELD": "hs_object_id"  
        "LOWER_BOUND": "50"  
        "UPPER_BOUND": "16726619290"  
        "NUM_PARTITIONS": "10"  
    }  
)
```

```
connection_type="netsuiteerp",
connection_options={
    "connectionName": "connectionName",
    "ENTITY_NAME": "deposit",
    "API_VERSION": "v1",
    "NUM_PARTITIONS": "3"
}
```

Options de NetSuite connexion Oracle

Les options de connexion pour Oracle sont les NetSuite suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Nom de l' NetSuite entité Oracle. Exemple : dépôt.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l' NetSuite API Oracle Rest que vous souhaitez utiliser. La valeur sera v1, car Oracle ne prend NetSuite actuellement en charge que la version v1.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Liste des colonnes séparées par des virgules que vous souhaitez sélectionner pour l'entité sélectionnée.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête (partitionnement basé sur les champs).
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur inférieure inclusive du champ de partition choisi, utilisée dans le partitionnement basé sur des champs.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi, utilisée dans le partitionnement basé sur des champs.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire. Utilisé à la fois dans le partitionnement basé sur les champs et sur les enregistrements.
- **INSTANCEE_URL**(String) - URL d' NetSuite instance valide avec format `https://{account-id}.suitetalk.api.netsuite.com`.

Limitations et remarques relatives au NetSuite connecteur Oracle

Les limitations ou remarques suivantes concernent le NetSuite connecteur Oracle :

- Les valeurs des paramètres `access_token` et `refresh_token` sont au format JSON Web Token (JWT). Le jeton d'accès est valide pendant 60 minutes tandis que le `refresh_token` est valide pendant sept jours.
- Lors de la génération de l'identifiant client et du secret client, si vous sélectionnez « CLIENT PUBLIC » en plus de « OCTROI DU CODE D'AUTORISATION », le jeton d'actualisation n'est valide que pendant trois heures et ne peut être utilisé qu'une seule fois.
- Vous pouvez récupérer au maximum 1 000 000 d'enregistrements à l'aide du connecteur.
- Les partitions sont créées de telle sorte que chaque partition récupère les enregistrements par multiples de 1000, sauf peut-être la dernière qui récupère les enregistrements restants.

Connexion au OpenSearch service dans AWS Glue Studio

AWS Glue fournit un support intégré pour Amazon OpenSearch Service. AWS Glue Studio fournit une interface visuelle pour se connecter à Amazon OpenSearch Service, créer des tâches d'intégration de données et les exécuter sur AWS Glue Studio environnement d'exécution Spark sans serveur. Cette fonctionnalité n'est pas compatible avec le OpenSearch Service serverless.

AWS Glue Studio crée une connexion unifiée pour Amazon OpenSearch Service. Pour de plus amples informations, veuillez consulter [Considérations](#).

Rubriques

- [Création d'une connexion OpenSearch de service](#)
- [Création d'un nœud OpenSearch de source de service](#)
- [Création d'un nœud cible de OpenSearch service](#)
- [Options avancées](#)

Création d'une connexion OpenSearch de service

Prérequis :

- Identifiez le point de terminaison *aosEndpoint* et le port du domaine que *aosPort* vous souhaitez consulter, ou créez la ressource en suivant les instructions de la documentation Amazon OpenSearch Service. Pour plus d'informations sur la création d'un domaine, consultez [la section Création et gestion OpenSearch de domaines Amazon Service](#) dans la documentation Amazon OpenSearch Service.

Un point de terminaison de domaine Amazon OpenSearch Service aura le formulaire par défaut suivant, `https://search - domainName -unstructuredIdContent. region.es.amazonaws.com`. Pour plus d'informations sur l'identification du point de terminaison de votre domaine, consultez la section [Création et gestion des domaines Amazon OpenSearch Service](#) dans la documentation Amazon OpenSearch Service.

Identifiez ou générez des informations d'authentification HTTP de base, *aosUser* et *aosPassword* pour votre domaine.

Pour configurer une connexion au OpenSearch service, procédez comme suit :

1. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification OpenSearch de service. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé USERNAME contenant la valeur. *aosUser*
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé PASSWORD contenant la valeur. *aosPassword*
2. Dans la AWS Glue console, créez une connexion en suivant les étapes décrites dans [the section called "Ajouter une AWS Glue connexion"](#). Après avoir créé la connexion, conservez le nom de la connexion pour une utilisation future dans AWS Glue. *connectionName*
 - Lorsque vous sélectionnez un type de connexion, sélectionnez OpenSearch Service.
 - Lorsque vous sélectionnez un point de terminaison de domaine, fournissez *aosEndpoint*.
 - Lorsque vous sélectionnez un port, indiquez *aosPort*.
 - Lorsque vous sélectionnez un AWS secret, fournissez *secretName*.

Création d'un nœud OpenSearch de source de service

Prérequis

- Une connexion AWS Glue OpenSearch de service, configurée avec un AWS Secrets Manager secret, comme décrit dans la section précédente, [the section called “Création d'une connexion OpenSearch de service”](#).
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.
- Un index des OpenSearch services que vous aimeriez lire, *aosIndex*.

Ajouter une source OpenSearch de données de service

Pour ajouter une source de données — nœud OpenSearch de service :

1. Choisissez la connexion pour votre source OpenSearch de données de service. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Create OpenSearch Service connection. Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion OpenSearch de service”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Fournissez Index, l'index que vous souhaitez lire.
3. Vous pouvez éventuellement fournir Query, une OpenSearch requête permettant de fournir des résultats plus spécifiques. Pour plus d'informations sur la rédaction de OpenSearch requêtes, consultez [the section called “Lire depuis le OpenSearch service”](#).
4. Dans Propriétés du OpenSearch service personnalisé, entrez les paramètres et les valeurs nécessaires.

Création d'un nœud cible de OpenSearch service

Prérequis

- Une connexion AWS Glue OpenSearch de service, configurée avec un AWS Secrets Manager secret, comme décrit dans la section précédente, [the section called “Création d'une connexion OpenSearch de service”](#).
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.

- Un index des OpenSearch services dans lequel vous souhaitez écrire, *aosIndex*.

Ajouter une cible OpenSearch de données de service

Pour ajouter une cible de données — nœud OpenSearch de service :

1. Choisissez la connexion pour votre source OpenSearch de données de service. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Create OpenSearch Service connection. Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion OpenSearch de service”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Fournissez Index, l'index que vous souhaitez lire.
3. Dans Propriétés du OpenSearch service personnalisé, entrez les paramètres et les valeurs nécessaires.

Options avancées

Vous pouvez fournir des options avancées lors de la création d'un nœud OpenSearch de service. Ces options sont les mêmes que celles disponibles lors de la programmation AWS Glue de scripts Spark.

Consultez [the section called “OpenSearch Connexions de service”](#).

Connexion à Okta

L'API Okta est l'interface programmatique d'Okta, utilisée pour gérer des comptes et des campagnes Okta volumineux ou complexes. Si vous êtes un utilisateur d'Okta, vous pouvez vous connecter AWS Glue à votre compte Okta. Vous pouvez ensuite utiliser Okta comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre Okta et AWS des services ou d'autres applications prises en charge.

Rubriques

- [AWS Glue support pour Okta](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)

- [Configuration d'Okta](#)
- [Configuration des connexions Okta](#)
- [Lecture à partir d'entités Okta](#)
- [Référence des options de connexion Okta](#)
- [Étapes de création d'un nouveau compte Okta et d'une application pour développeurs](#)
- [Limites](#)

AWS Glue support pour Okta

AWS Glue prend en charge Okta comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données d'Okta.

Soutenu en tant que cible ?

Non

Versions d'API Okta prises en charge

v1.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

```
}  
]  
}
```

Vous pouvez également utiliser les politiques IAM gérées suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration d'Okta

Avant de pouvoir transférer des données AWS Glue vers ou depuis Okta, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous avez un compte Okta. Pour plus d'informations sur la création d'un compte, consultez [Étapes de création d'un nouveau compte Okta et d'une application pour développeurs](#).
- Votre compte Okta est activé pour accéder à l'API.
- Vous avez créé une intégration d' OAuth2 API dans votre compte Okta. Cette intégration fournit les informations d'identification du client qui AWS Glue permettent d'accéder à vos données en toute sécurité lorsqu'il effectue des appels authentifiés vers votre compte. Pour plus d'informations, reportez-vous aux étapes de création d'une application client et aux informations d'identification OAuth2 2.0 : étapes de création d'un nouveau compte Okta et d'une application pour développeurs
- Vous avez un compte Okta avec un OktaApiToken. Reportez-vous à la [documentation Okta](#).

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Okta. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Okta.

Configuration des connexions Okta

Okta prend en charge deux types de mécanismes d'authentification :

- OAuth auth : Okta prend en charge le type de AUTHORIZATION_CODE subvention.
 - Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. La AWS Glue console redirige l'utilisateur vers Okta où il doit se connecter et accorder AWS Glue les autorisations demandées pour accéder à son instance Okta.
 - Les utilisateurs peuvent choisir de créer leur propre application connectée dans Okta et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Okta pour se connecter et autoriser l'accès AWS Glue à leurs ressources.
 - Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
 - Pour plus d'informations, consultez la [documentation publique d'Okta sur la création d'une application connectée pour le OAuth flux de code d'autorisation](#).
- Authentification personnalisée :
 - Pour consulter la documentation publique d'Okta sur la génération des clés d'API requises pour une autorisation personnalisée, consultez la documentation [Okta](#).

Pour configurer une connexion Okta :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes. Il est nécessaire de créer un secret pour chaque connexion dans AWS Glue.
 - a. Pour l' OAuth authentification :
 - Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET comme clé.
 - b. Pour une authentification personnalisée :
 - Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec OktaApiToken comme clé.

2. Dans AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 - a. Sous Connexions, choisissez Créer une connexion.
 - b. Lorsque vous sélectionnez une source de données, sélectionnez Okta.
 - c. Indiquez votre sous-domaine Okta.
 - d. Sélectionnez l'URL du domaine Okta de votre compte Okta.
 - e. Sélectionnez le rôle IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- f. Sélectionnez le type d'authentification pour vous connecter à la source de données.
 - g. Pour le type OAuth2 d'authentification, fournissez l'application client gérée par l'utilisateur ClientId de l'application Okta.
 - h. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - i. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.
4. Dans la configuration de votre AWS Glue tâche, fournissez connectionName une connexion réseau supplémentaire.

Lecture à partir d'entités Okta

Prérequis

- Un objet Okta dont vous aimeriez lire un extrait. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Applications	Oui	Oui	Non	Oui	Non
Appareils	Oui	Oui	Non	Oui	Oui
Groups	Oui	Oui	Oui	Oui	Oui
Users	Oui	Oui	Oui	Oui	Oui
Types d'utilisateurs	Non	Non	Non	Oui	Non

Exemple

```
okta_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Okta",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "applications",
        "API_VERSION": "v1"
    }
)
```

Détails des entités et des champs Okta

Liste des entités :

- Application : <https://developer.okta.com/docs/api/openapi/okta-management/management/tag/Application/>

- Appareil : <https://developer.okta.com/docs/api/openapi/okta-management/management/tag/Device/>
- Groupe : <https://developer.okta.com/docs/api/openapi/okta-management/management/tag/Group/>
- Utilisateur : <https://developer.okta.com/docs/api/openapi/okta-management/management/tag/User/>
- Type d'utilisateur : <https://developer.okta.com/docs/api/openapi/okta-management/management/tag/UserType/>

Requêtes de partitionnement

Des options Spark supplémentaires `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, `NUM_PARTITIONS` peuvent être fournies si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur limite inférieure inclusive du champ de partition choisi.

Pour la date, nous acceptons le format de date Spark utilisé dans les requêtes SQL Spark.

Exemple de valeurs valides : "2024-02-06".

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`: nombre de partitions.

Exemple

```
okta_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="okta",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "lastUpdated",  
        "API_VERSION": "v1",  
        "PARTITION_FIELD": "lastMembershipUpdated",  
        "LOWER_BOUND": "2022-08-10T10:28:46.000Z",  
        "UPPER_BOUND": "2024-08-10T10:28:46.000Z",  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Référence des options de connexion Okta

Les options de connexion pour Okta sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Okta.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Okta Rest que vous souhaitez utiliser. Exemple : v1.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Étapes de création d'un nouveau compte Okta et d'une application pour développeurs


Créez un compte développeur sur Okta pour accéder à l'API Okta. Un compte de développeur Okta gratuit donne accès à la plupart des fonctionnalités clés requises pour accéder à l'API Okt.

Pour créer un compte développeur sur Okta

1. Accédez à <https://developer.okta.com/signup/>.
2. Entrez les informations du compte (e-mail, prénom, nom de famille et pays/région). Choisissez Je ne suis pas un robot, puis inscrivez-vous.
3. Un e-mail de vérification est envoyé à votre adresse e-mail enregistrée. Vous recevrez un lien dans votre e-mail pour activer votre compte de développeur Okta. Choisissez Activer.
4. Vous serez redirigé vers la page de réinitialisation du mot de passe. Entrez le nouveau mot de passe deux fois et choisissez Réinitialiser le mot de passe.
5. Vous serez redirigé vers le tableau de bord de votre compte développeur Okta.

Pour créer une application cliente et des informations d'identification OAuth 2.0

1. Dans le tableau de bord des développeurs, choisissez Créer une intégration d'applications.



2. La fenêtre d'intégration de créer une nouvelle application apparaîtra et présentera différentes méthodes de connexion. Sélectionnez OIDC —OpenID Connect.
3. Faites défiler la page jusqu'à la section Type d'application. Sélectionnez en tant qu'application Web, puis cliquez sur Suivant.
4. Sur l'écran « Nouvelle intégration d'applications Web », renseignez les informations suivantes :
 - Nom de l'intégration de l'application : entrez le nom de l'application.
 - Type de subvention : choisissez le code d'autorisation et le jeton d'actualisation dans la liste.
 - Redirection de connexion URIs : choisissez Ajouter une URI et **https://{regioncode}.console.aws.amazon.com/appflow/oauth** ajoutez-la. Par exemple, si vous utilisez, us-west-2 (Oregon) vous pouvez ajouter **https://us-east-1.console.aws.amazon.com/appflow/oauth**.
 - Accès contrôlé : assignez l'application à vos groupes d'utilisateurs selon vos besoins et choisissez Enregistrer.
5. Votre identifiant client et votre secret client sont générés.

Limites

Les limites du connecteur Okta sont les suivantes :

- Pour l'entité « Applications », un seul filtre peut être appliqué. Si plus d'un filtre est appliqué, 400 demandes erronées sont renvoyées avec un résumé des erreurs : « Critères de recherche non valides ».

- Le tri par ne peut être pris en charge que par des requêtes de recherche. Par exemple, `http://dev-15940405.okta.com/api/v1/groups?search=type e.q. "OKTA_GROUP"&sortBy=lastUpdated&sortOrder=asc`

Connexion à PayPal

PayPal est un système de paiement qui facilite les transferts d'argent en ligne entre les parties, tels que les transferts entre clients et fournisseurs en ligne. Si vous êtes un PayPal utilisateur, votre compte contient des données relatives à vos transactions, telles que leurs payeurs, leurs dates et leurs statuts. Vous pouvez l'utiliser AWS Glue pour transférer des données depuis certains AWS services ou PayPal vers d'autres applications prises en charge.

Rubriques

- [AWS Glue support pour PayPal](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration PayPal](#)
- [Configuration des PayPal connexions](#)
- [Lecture à partir d' PayPal entités](#)
- [PayPal options de connexion](#)
- [Limitations et remarques relatives au PayPal connecteur](#)

AWS Glue support pour PayPal

AWS Glue prend en charge PayPal les éléments suivants :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données à partir de PayPal.

Soutenu en tant que cible ?

Non.

Versions PayPal d'API prises en charge

Les versions PayPal d'API suivantes sont prises en charge :

- v1

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration PayPal

Avant de pouvoir AWS Glue transférer des données depuis PayPal, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un PayPal compte avec des informations d'identification client.
- Votre PayPal compte dispose d'un accès à l'API avec une licence valide.

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre PayPal compte. Pour les connexions classiques, vous n'avez rien d'autre à faire dans PayPal.

Configuration des PayPal connexions

PayPal prend en charge le type de subvention CLIENT CREDENTIALS pour OAuth2.

- Ce type de subvention est considéré comme un système OAuth 2.0 à deux volets car il est utilisé par les clients pour obtenir un jeton d'accès en dehors du contexte d'un utilisateur. AWS Glue est capable d'utiliser l'ID client et le secret du client pour authentifier PayPal APIs ceux fournis par les services personnalisés que vous définissez.
- Chaque service personnalisé appartient à un utilisateur utilisant uniquement l'API, qui dispose d'un ensemble de rôles et d'autorisations autorisant le service à effectuer des actions spécifiques. Un jeton d'accès est associé à un seul service personnalisé.
- Ce type d'autorisation donne lieu à un jeton d'accès de courte durée qui peut être renouvelé en appelant à nouveau le /v2/oauth2/token point de terminaison.
- Pour consulter PayPal la documentation publique de la OAuth version 2.0 avec les informations d'identification du client, voir [Authentification](#).

Pour configurer une PayPal connexion, procédez comme suit :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir le secret du consommateur de l'application connectée avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
 - b. Remarque : vous devez créer un secret pour vos connexions dans AWS Glue.

1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez PayPal.
 - b. Indiquez INSTANCE_URL l'instance PayPal à laquelle vous souhaitez vous connecter.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Obtenir des informations d'identification OAuth 2.0

Pour appeler l'API Rest, vous devez échanger votre identifiant client et votre secret client contre un jeton d'accès. Pour plus d'informations, consultez [Commencer avec PayPal REST APIs](#).

Lecture à partir d' PayPal entités

Prérequis

Un PayPal objet que vous aimeriez lire. Vous aurez besoin du nom de l'objet, transaction.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
transaction	Oui	Oui	Non	Oui	Oui

Exemple :

```
paypal_read = glueContext.create_dynamic_frame.from_options(
    connection_type="paypal",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "transaction",
        "API_VERSION": "v1",
        "INSTANCE_URL": "https://api-m.paypal.com"
    }
)
```

PayPal détails de l'entité et du champ :

Entités avec métadonnées statiques :

Entité	Champ	Type de données	Opérateurs pris en charge
transaction	date_initiation_de_transaction	DateTime	Entre
	date_heure de la dernière actualisation	Chaîne	N/A
	type_d'instrument de paiement	Chaîne	=
	balance_affecting_records_only	Chaîne	=
	identifiant du magasin	Chaîne	=

Entité	Champ	Type de données	Opérateurs pris en charge
	identifiant_terminal	Chaîne	=
	monnaie_de transaction	Chaîne	=
	transaction_id	Chaîne	N/A
	état_de la transaction	Chaîne	N/A
	transaction_type	Chaîne	N/A
	information_transaction	Struct	N/A
	info_payeur	Struct	N/A
	information_d'expédition	Struct	N/A
	info_panier	Struct	N/A
	info_boutique	Struct	N/A
	info_vente	Struct	N/A
	information_incitative	Struct	N/A

Requêtes de partitionnement

Vous pouvez fournir les options supplémentaires de Spark

`PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, et `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur inférieure inclusive du champ de partition choisi.

Pour le champ Datetime, nous acceptons la valeur au format ISO.

Exemples de valeurs valides :

```
"2024-07-01T00:00:00.000Z"
```

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: le nombre de partitions.

Le champ suivant est pris en charge pour le partitionnement par entité :

Nom de l'entité	Champs de partitionnement	Type de données
transaction	date_initiation_de_transaction	DateTime

Exemple :

```
paypal_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="paypal",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "transaction",  
        "API_VERSION": "v1",  
        "PARTITION_FIELD": "transaction_initiation_date"  
        "LOWER_BOUND": "2024-07-01T00:00:00.000Z"  
        "UPPER_BOUND": "2024-07-02T00:00:00.000Z"  
        "NUM_PARTITIONS": "10"  
    }  
)
```

PayPal options de connexion

Les options de connexion suivantes sont disponibles pour PayPal :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans PayPal.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. PayPal Version de l'API Rest que vous souhaitez utiliser.
- SELECTED_FIELDS(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.

- `FILTER_PREDICATE(String)` - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- `QUERY(String)` - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- `PARTITION_FIELD(String)` - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- `LOWER_BOUND(String)` - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- `UPPER_BOUND(String)` - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS(Entier)` - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Limitations et remarques relatives au PayPal connecteur

Les limitations ou remarques suivantes concernent le PayPal connecteur :

- La [documentation PayPal des transactions](#) indique qu'il faut au maximum trois heures pour que les transactions exécutées apparaissent dans l'appel de transactions de liste. Cependant, il a été observé que cela prenait plus de temps que cela selon le [last_refreshed_datetime](#).
last_refreshed_datetimeVoici la durée pendant laquelle vous avez des données disponibles auprès du APIs.
- Si le `last_refreshed_datetime` est inférieur à la valeur demandée, `end_date` il `end_date` devient égal à `last_refreshed_datetime` car nous n'avons que des données jusqu'à ce moment-là.
- Ce `transaction_initiation_date` champ est un filtre obligatoire à fournir pour l'entité et la plage de dates [maximale prise en charge](#) pour ce champ est de 31 jours.
- Lorsque vous appelez la demande d'API d'entité avec des filtres (paramètres de requête) autres que le `transaction_initiation_date` champ, il est prévu que la valeur du [ending_balance](#) champ ne soit pas extraite dans la réponse.

Connexion à Pendo

Pendo fournit une banque de données riche pour les données d'interaction des utilisateurs. Les clients transféreront ces données AWS afin de les associer à d'autres données sur le produit,

d'effectuer des analyses et des tableaux de bord supplémentaires et de définir des alertes s'ils le souhaitent.

Rubriques

- [AWS Glue support pour Pendo](#)
- [Politiques contenant les opérations d'API pour la création et l'utilisation de connexions](#)
- [Configuration de Pendo](#)
- [Configuration des connexions Pendo](#)
- [Lecture depuis des entités Pendo](#)
- [Options de connexion Pendo](#)
- [Limites](#)

AWS Glue support pour Pendo

AWS Glue prend en charge Pendo comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Pendo.

Soutenu en tant que cible ?

Non

Versions de l'API Pendo prises en charge

v1

Politiques contenant les opérations d'API pour la création et l'utilisation de connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
```

```
        "Action": [
            "glue:ListConnectionTypes",
            "glue:DescribeConnectionType",
            "glue:RefreshOAuth2Tokens",
            "glue:ListEntities",
            "glue:DescribeEntity"
        ],
        "Resource": "*"
    }
}
```

Si vous ne souhaitez pas utiliser la méthode précédente, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#) — Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#) — Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Pendo

Avant de pouvoir AWS Glue effectuer un transfert depuis Pendo, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous possédez un compte Pendo `apiKey` avec `write access` activé.
- Votre compte Pendo dispose d'un accès à l'API avec une licence valide.

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Pendo. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Pendo.

Configuration des connexions Pendo

Pendo prend en charge l'authentification personnalisée.

Pour consulter la documentation publique de Pendo sur la génération des clés d'API requises pour une autorisation personnalisée, consultez [Authentication — Documentation de l'API REST de Pendo](#)

Pour configurer une connexion Pendo :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - Pour les applications connectées gérées par le client, Secret doit contenir l'application connectée Consumer Secret dont apiKey la clé est utilisée.

Note

Il est indispensable de créer un secret par connexion AWS Glue.

2. Dans AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez une source de données, sélectionnez Pendo.
 - b. Indiquez `instanceUrl` l'instance Pendo à laquelle vous souhaitez vous connecter.
 - c. Sélectionnez le rôle IAM pour lequel AWS Glue vous pouvez assumer et qui dispose des autorisations nécessaires pour effectuer les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

```
}
```

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.
 4. Dans la configuration de votre AWS Glue tâche, fournissez `connectionName` une connexion réseau supplémentaire.

Lecture depuis des entités Pendo

Prérequis

Un objet Pendo dont vous aimeriez lire un extrait. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

- [Fonctionnalité](#)
- [Guide](#)
- [Page](#)
- [Rapport](#)
- [Données du rapport](#)
- [Visiteur](#)
- [Compte](#)
- [Événement](#)
- [Événement phare](#)
- [Événement du guide](#)
- [Événement de page](#)
- [Événement du sondage](#)
- [Suivre l'événement](#)

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Fonctionnalité	Non	Non	Non	Oui	Non
Guide	Non	Non	Non	Oui	Non
Page	Non	Non	Non	Oui	Non
Rapport	Non	Non	Non	Oui	Non
Données du rapport	Non	Non	Non	Oui	Non
Visiteur (API d'agrégation)	Oui	Non	Oui	Oui	Non
Compte (API d'agrégation)	Oui	Non	Oui	Oui	Non
Événement (API d'agrégation)	Oui	Non	Oui	Oui	Non
Événement de fonctionnalité (API d'agrégation)	Oui	Non	Oui	Oui	Oui
Événement du guide (API d'agrégation)	Oui	Non	Oui	Oui	Oui
Compte (API d'agrégation)	Oui	Non	Oui	Oui	Oui

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Événement de page (API d'agrégation)	Oui	Non	Oui	Oui	Oui
Événement de sondage (API d'agrégation)	Oui	Non	Oui	Oui	Oui
Suivi des événements (API d'agrégation)	Oui	Non	Oui	Oui	Oui

Exemple

```
Pendo_read = glueContext.create_dynamic_frame.from_options(
    connection_type="glue.spark.Pendo",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "feature",
        "API_VERSION": "v1",
        "INSTANCE_URL": "instanceUrl"
    }
)
```

Requêtes de partitionnement

Vous pouvez fournir les options supplémentaires de Spark `PARTITION_FIELD_LOWER_BOUND`, `UPPER_BOUND`, et `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.

- LOWER_BOUND: une valeur inférieure inclusive du champ de partition choisi.

Pour le DateTime champ, nous acceptons la valeur au format ISO.

Exemple de valeur valide :

```
"2024-07-01T00:00:00.000Z"
```

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: le nombre de partitions.

Le tableau suivant décrit les détails relatifs à la prise en charge des champs de partitionnement des entités :

Nom de l'entité

Événement

Événement phare

Événement du guide

Événement de page

Événement du sondage

Suivre l'événement

Exemple :

```
pendo_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="glue.spark.pendo",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "event",  
        "API_VERSION": "v1",  
        "INSTANCE_URL": "instanceUrl",  
        "NUM_PARTITIONS": "10",  
        "PARTITION_FIELD": "appId",  
        "LOWER_BOUND": "4656"
```

```
"UPPER_BOUND": "7788"  
}
```

Options de connexion Pendo

Les options de connexion pour Pendo sont les suivantes :

- **ENTITY_NAME**(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Pendo.
- **INSTANCE_URL**(String) - (Obligatoire) Une URL d'instance Pendo valide avec les valeurs autorisées suivantes :
 - [Par défaut](#)
 - [L'Europe](#)
 - [US1](#)
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Rest de Pendo Engage que vous souhaitez utiliser. Par exemple : 3.0.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Limites

Les limites du connecteur Pendo sont les suivantes :

- La pagination n'est pas prise en charge dans Pendo.

- La filtration est prise en charge uniquement par les objets de l'API Aggregate (AccountEventFeature EventGuide Events,Page Event,Poll Event,Track Event,, etVisitor)
- DateTimeRange est un paramètre de filtre obligatoire pour les objets de l'API Aggregate (EventFeature Event,Guide Events,Page Event,, Poll Event,Track Event)
- La période DayRange sera arrondie au début de la période dans le fuseau horaire. Par exemple, si le filtre fourni 2023-01-12T07:55:27.065Z est, cette période sera arrondie au début de la période, c'est-à-dire 2023-01-12T00:00:00Z.

Connexion à Pipedrive

Pipedrive est un CRM pour le pipeline des ventes conçu pour aider les petites entreprises à gérer les prospects, à suivre les activités de vente et à conclure davantage de ventes. Pipedrive permet aux équipes commerciales des petites entreprises de : rationaliser les processus et consolider les données de vente dans un seul outil de vente CRM unifié. Si vous êtes un utilisateur de Pipedrive, vous pouvez vous connecter AWS Glue à votre compte Pipedrive. Vous pouvez ensuite utiliser Pipedrive comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre Pipedrive et des AWS services ou d'autres applications prises en charge.

Rubriques

- [AWS Glue support pour Pipedrive](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Pipedrive](#)
- [Configuration des connexions Pipedrive](#)
- [Lecture à partir d'entités Pipedrive](#)
- [Référence des options de connexion Pipedrive](#)
- [Limites](#)

AWS Glue support pour Pipedrive

AWS Glue prend en charge Pipedrive comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Pipedrive.

Soutenu en tant que cible ?

Non

Versions de l'API Pipedrive prises en charge

v1.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Vous pouvez également utiliser les politiques IAM gérées suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs

bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Pipedrive

Avant de pouvoir AWS Glue transférer des données depuis Pipedrive, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous avez un compte Pipedrive.
- Votre compte Pipedrive est activé pour accéder à l'API.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Pipedrive. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Pipedrive.

Configuration des connexions Pipedrive

Pipedrive prend en charge le type de subvention `AUTHORIZATION_CODE` pour `OAuth2`

- Ce type de subvention est considéré comme « à trois étapes » `OAuth` car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. L'utilisateur qui crée une connexion peut par défaut s'appuyer sur une application connectée qu'il AWS Glue possède et dans laquelle il n'a pas besoin de fournir d'informations `OAuth` connexes, à l'exception de l'instanceurl de Pipedrive. La AWS Glue console redirigera l'utilisateur vers Pipedrive où il devra se connecter et accorder AWS Glue les autorisations demandées pour accéder à son instance Pipedrive.
- Les utilisateurs doivent choisir de créer leur propre application connectée dans Pipedrive et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Pipedrive pour se connecter et autoriser l'accès AWS Glue à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est actif pendant une heure et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- Pour plus d'informations, consultez [la documentation sur la création d'une application connectée pour le flux `AUTHORIZATION\_CODE` `OAuth`](#) .

Pour configurer une connexion Pipedrive :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes. Il est nécessaire de créer un secret pour chaque connexion dans AWS Glue.
 - a. Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec la clé `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
2. Dans AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 - a. Sous Connexions de données, choisissez Créer une connexion.
 - b. Lorsque vous sélectionnez une source de données, sélectionnez Pipedrive.
 - c. Indiquez l'URL de votre instance Pipedrive.
 - d. Sélectionnez le rôle IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- e. Fournissez l'application client gérée par l'utilisateur ClientId du Pipedrive auquel vous souhaitez vous connecter.
- f. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
- g. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.

3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`. Choisissez Suivant.
4. Indiquez le nom de la connexion et choisissez Next.
5. Sur la page suivante, choisissez Créer une connexion. Il vous sera demandé de vous connecter à Pipedrive. Entrez votre nom d'utilisateur et votre mot de passe, puis choisissez Se connecter.
6. Une fois connecté, choisissez Continuer vers l'application. Votre connexion est maintenant prête à être utilisée.
7. Dans la configuration de votre AWS Glue tâche, fournissez `connectionName` une connexion réseau supplémentaire.

Lecture à partir d'entités Pipedrive

Prérequis

- Un objet Pipedrive dont vous aimeriez lire un extrait. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Activités	Oui	Oui	Non	Oui	Oui
Type d'activité	Non	Non	Non	Oui	Non
Journaux d'appels	Non	Non	Non	Oui	Non
Devises	Oui	Oui	Non	Oui	Non
Offres	Oui	Oui	Oui	Oui	Oui
Prospects	Oui	Oui	Oui	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Sources de plomb	Non	Oui	Non	Oui	Non
Étiquettes en plomb	Non	Non	Non	Non	Non
Remarques	Oui	Oui	Oui	Oui	Oui
Organisation	Oui	Oui	Non	Oui	Oui
Jeux d'autorisations	Oui	Non	Non	Oui	Non
Personnes	Oui	Oui	Oui	Oui	Oui
Pipelines	Non	Oui	Non	Oui	Non
Produits	Oui	Oui	Non	Oui	Oui
Rôles	Non	Oui	Non	Oui	Non
Étapes	Oui	Oui	Non	Oui	Non
Users	Non	Non	Non	Oui	Non

Exemple

```

pipedrive_read= glueContext.create_dynamic_frame.from_options(
    connection_type="PIPEDRIVE",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "activites",
        "API_VERSION": "v1"
    }

```

Détails des entités et des champs de Pipedrive

Liste des entités :

- Activités : <https://developers.pipedrive.com/docs/api/v1/Activities>
- Type d'activité : <https://developers.pipedrive.com/docs/api/v1/ActivityTypes>
- Journaux d'appels : <https://developers.pipedrive.com/docs/api/v1/CallLogs>
- Devises : <https://developers.pipedrive.com/docs/api/v1/Currencies>
- Offres : <https://developers.pipedrive.com/docs/api/v1/Deals>
- Prospects : <https://developers.pipedrive.com/docs/api/v1/Leads>
- Sources de plomb : <https://developers.pipedrive.com/docs/api/v1/LeadSources>
- Étiquettes en plomb : <https://developers.pipedrive.com/docs/api/v1/LeadLabels>
- Remarques : <https://developers.pipedrive.com/docs/api/v1/Notes>
- Organisations : <https://developers.pipedrive.com/docs/api/v1/Organizations>
- Ensembles d'autorisations : <https://developers.pipedrive.com/docs/api/v1/PermissionSets>
- Personnes : <https://developers.pipedrive.com/docs/api/v1/Persons>
- Canalisations : <https://developers.pipedrive.com/docs/api/v1/Pipelines>
- Produits : <https://developers.pipedrive.com/docs/api/v1/Products>
- Rôles : <https://developers.pipedrive.com/docs/api/v1/Roles>
- Étapes : <https://developers.pipedrive.com/docs/api/v1/Stages>
- Utilisateurs : <https://developers.pipedrive.com/docs/api/v1/Users>

Entité	Type de données	Opérateurs pris en charge
Activités, offres, notes, organisation, personnes et produits.	Date	'='
	Entier	'='
	Chaîne	'='
	Booléen	'='

Requêtes de partitionnement

Dans Pipedrive, un seul champ (`due_date`) de l'entité `Activities` prend en charge le partitionnement basé sur les champs. Il s'agit d'un champ de date.

Des options Spark supplémentaires `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, `NUM_PARTITIONS` peuvent être fournies si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur inférieure inclusive du champ de partition choisi.

Pour la date, nous acceptons le format de date Spark utilisé dans les requêtes SQL Spark. Exemple de valeurs valides : `"2024-02-06"`.

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`: nombre de partitions.

Exemple

```
pipedrive_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="PIPEDRIVE",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "activites",  
        "API_VERSION": "v1",  
        "PARTITION_FIELD": "due_date"  
        "LOWER_BOUND": "2023-09-07T02:03:00.000Z"  
        "UPPER_BOUND": "2024-05-07T02:03:00.000Z"  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Référence des options de connexion Pipedrive

Les options de connexion pour Pipedrive sont les suivantes :

- `ENTITY_NAME`(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Pipedrive.

- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Rest de Pipedrive que vous souhaitez utiliser. Exemple : v1.
- **INSTANCE_URL**(String) - (Obligatoire) URL de l'instance sur laquelle l'utilisateur souhaite exécuter les opérations. Exemple : v1.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Limites

Les limites du connecteur Pipedrive sont les suivantes :

- Pipedrive prend en charge le partitionnement basé sur le terrain pour une seule entité (Activités).
- Pipedrive prend en charge le partitionnement basé sur les enregistrements pour les entités Activités, Offres, Notes, Personnes, Organisations et Produits.
- Dans l'entité Deals, le champ de statut en tant que filtre renverra tous les enregistrements si une valeur de filtre de valeur non valide est utilisée.
- Dans l'entité Deals, la commande avec plusieurs champs n'est pas prise en charge.
- Pour obtenir des données de performance, nous utilisons un AWS compte local. Cependant, en raison de la limitation de l'actualisation locale du jeton d'accès, la AWS Glue tâche de traitement de 1 Go de données échoue. Par conséquent, nous avons optimisé le test de performance avec 179 Mo de données, et les résultats ci-dessus sont basés sur cette optimisation. Néanmoins, nous avons observé qu'avec l'augmentation du nombre de partitions, le point de terminaison SaaS prend plus de temps qu'une partition unique. Nous avons consulté l'équipe d'assistance de Pipedrive à propos de ce comportement, qui nous a informés que Pipedrive limitait silencieusement les

demandes et retardait la réponse. Par conséquent, lorsque vous exécutez la AWS Glue tâche avec de grands ensembles de données ou que vous appelez plusieurs fois le même point de terminaison d'API, cela peut entraîner un problème de délai d'attente en raison de l'implémentation de l'API Pipedrive. Cependant, les temps de réponse du connecteur et de la cale diminuent comme prévu en raison de l'augmentation du nombre de partitions.

Connexion à Productboard

Productboard est le système de gestion des produits qui aide les équipes produit à commercialiser les bons produits plus rapidement. Plus de 3 000 entreprises modernes axées sur les produits, comme Zendesk UiPath et Microsoft, utilisent Productboard pour comprendre ce dont les utilisateurs ont réellement besoin, hiérarchiser les prochaines étapes et rallier tout le monde autour de leur feuille de route.

Rubriques

- [AWS Glue support pour Productboard](#)
- [Politiques contenant les opérations d'API pour la création et l'utilisation de connexions](#)
- [Configuration de Productboard](#)
- [Configuration des connexions Productboard](#)
- [Lecture depuis les entités de Productboard](#)
- [Options de connexion au carte-produit](#)
- [Création d'un compte Productboard](#)
- [Limites](#)

AWS Glue support pour Productboard

AWS Glue prend en charge Productboard comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Productboard.

Soutenu en tant que cible ?

Non.

Versions de l'API Productboard prises en charge

v1

Politiques contenant les opérations d'API pour la création et l'utilisation de connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode précédente, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#) — Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#) — Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Productboard

Avant de pouvoir AWS Glue utiliser le transfert depuis Productboard, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous avez un compte Productboard avec e-mail et mot de passe. Pour plus d'informations sur la création d'un compte, consultez [Création d'un compte Productboard](#).
- Vous devez avoir créé AWS un compte avec l'accès au service à AWS Glue.
- Vous disposez des informations d'authentification d'un compte Productboard : soit un jeton JWT si vous souhaitez utiliser une authentification personnalisée, soit un identifiant client et un code secret si vous souhaitez utiliser OAuth2.
- Si l'utilisateur souhaite l'utiliser OAuth2, [enregistrez votre application auprès de Productboard](#) et configurez-la en suivant les instructions de la section [Comment intégrer Productboard via OAuth2 la documentation destinée aux développeurs](#).

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Productboard. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Productboard.

Configuration des connexions Productboard

Productboard prend en charge l'authentification personnalisée et OAuth2. Car OAuth2, Productboard soutient le type de AUTHORIZATION_CODE subvention.

- Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. L'utilisateur qui crée une connexion peut par défaut s'appuyer sur une application connectée AWS Glue dont il est propriétaire et où il n'a pas besoin de fournir d'informations OAuth connexes, à l'exception de son identifiant client Productboard et de son secret client. La AWS Glue console redirige l'utilisateur vers Productboard où il doit se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Productboard.
- Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans Productboard et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Productboard pour se connecter et autoriser l'accès AWS Glue à leurs ressources.

- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- Pour consulter la documentation publique de Productboard sur la création d'une application connectée pour AUTHORIZATION_CODE OAuth Flow, consultez [Comment intégrer à Productboard via OAuth2 la documentation destinée aux développeurs](#).

Pour configurer une connexion Productboard :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - Pour OAuth l'authentification — Pour l'application connectée gérée par le client : Secret doit contenir le secret du consommateur de l'application connectée avec USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET comme clé.
 - Pour Custom auth — Pour une application connectée gérée par le client : Secret doit contenir l'application connectée JWT token avec access_token comme clé.
2. Dans AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez une source de données, sélectionnez Productboard.
 - b. Sélectionnez le rôle IAM pour lequel AWS Glue vous pouvez assumer et qui dispose des autorisations nécessaires pour effectuer les actions suivantes :

 Note

Il est indispensable de créer un secret par connexion AWS Glue.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
```

```
    ],  
    "Resource": "*"    
  }  
]  
}
```

- c. Sélectionnez le type d'authentification pour vous connecter à la source de données :
 - Pour OAuth l'authentification : indiquez le et Token URL User Managed Client Application ClientId de l'application Productboard.
 - d. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.
 4. Dans la configuration de votre AWS Glue tâche, fournissez connectionName une connexion réseau supplémentaire.

Lecture depuis les entités de Productboard

Prérequis

Un objet Productboard dont vous aimeriez lire un extrait. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

- [Signalements d'abus](#)
- [Automation](#)
- [Campagnes](#)
- [Détails du clic](#)
- [Listes](#)
- [Membres](#)
- [Détails ouverts](#)
- [Segments](#)
- [Boutiques](#)
- [Désabonné](#)

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Fonctionnalités	Oui	Oui	Non	Oui	Oui
Composants	Non	Oui	Non	Oui	Non
Produits	Non	Oui	Non	Oui	Non
Statuts des fonctionnalités	Non	Oui	Non	Oui	Oui
Définitions de champs personnalisés	Non	Oui	Non	Oui	Non
Valeurs de champs personnalisés	Oui	Oui	Non	Oui	Non

Exemple

```
Productboard_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Productboard",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "feature",
        "API_VERSION": "1"
    }
)
```

Informations sur l'entité et le champ du Productboard

- [Fonctions](#)
- [Composants](#)

- [Statuts des fonctionnalités](#)
- [Produits](#)
- [Définitions de champs personnalisés](#)
- [Valeurs des champs personnalisés](#)

Options de connexion au carte-produit

Les options de connexion pour Productboard sont les suivantes :

- ENTITY_NAME(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Productboard.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Rest de Productboard Engage que vous souhaitez utiliser. Par exemple : 3.0.
- SELECTED_FIELDS(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- FILTER_PREDICATE(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- QUERY(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

Création d'un compte Productboard

1. Accédez à la [page d'inscription de Productboard](#), entrez votre adresse e-mail et votre mot de passe, puis choisissez Log me in.
2. Dans le champ Nom du compte, saisissez le nom de votre compte Productboard, puis cochez la case J'accepte la politique de confidentialité.
3. Sur la page Maintenant créez votre espace de travail, dans le champ URL de l'espace de travail, entrez l'URL de votre nouvel espace de travail. Choisissez ensuite Continuer pour passer à la page suivante et fournir les informations restantes.

Cela crée votre compte d'essai. Le compte d'essai est gratuit pendant 15 jours. Une fois la période d'essai expirée, vous pouvez acheter un forfait payant. Notez votre adresse e-mail, votre mot de passe et l'URL de votre espace de travail. Vous aurez besoin de ces informations pour accéder à votre compte à l'avenir. »

Enregistrement d'une **OAuth2.0** application

1. Accédez à la [page de connexion de Productboard](#), saisissez votre adresse e-mail et votre mot de passe, puis choisissez Se connecter.
2. Sélectionnez l'icône Utilisateur dans le coin supérieur droit, puis choisissez Compte et facturation dans le menu déroulant.
3. Sélectionnez Extras, puis sélectionnez Applications enregistrées dans le menu déroulant.
4. Localisez et choisissez Enregistrer une application.
5. Entrez les informations suivantes :
 - Nom de l'application : nom de l'application.
 - Entreprise/organisation — Nom de votre entreprise ou organisation.
 - Site Web de l'application — Site Web de l'application.
 - URI de redirection — Un modèle d'URI de redirection est un chemin d'URI (ou une liste de chemins séparés par des virgules) vers lequel Productboard peut rediriger (si demandé) une fois le flux de connexion terminé. Par exemple, `https://ap-southeast-2\\.console\\.aws\\.amazon\\.com`
6. Sélectionnez Create (Créer).
7. L'ID client et le secret du client seront désormais visibles. Copiez-les et enregistrez-les dans un endroit sûr. Choisissez ensuite Terminé.

Note

Vos chaînes d'ID client et de secret client sont des informations d'identification utilisées pour établir une connexion avec ce connecteur lors de l'utilisation de AppFlow ou AWS Glue.

Récupération des informations d'identification CustomAuth

1. Accédez à la [page de connexion de Productboard](#), saisissez votre adresse e-mail et votre mot de passe, puis choisissez Log me in.

Vous serez redirigé vers la page d'accueil.

2. Sur la page d'accueil, accédez à Paramètres de l'espace de travail > Intégrations > Public APIs > Jeton d'accès.

 Note

Si la APIs section publique n'est pas visible, votre compte est peut-être associé au forfait Essentials. L'accès aux jetons d'API nécessite au moins un plan Pro. Les caractéristiques et les noms des forfaits sont sujets à modification. Pour plus d'informations sur les packages, consultez la section [Tarification de Productboard](#).

3. Choisissez + pour générer un nouveau jeton et assurez-vous de le stocker en toute sécurité pour référence future.

Création d'OAuth2.0 informations d'identification

Pour utiliser OAuth2.0 l'authentification avec le connecteur Productboard, vous devez enregistrer votre application sur la plateforme Productboard et générer un Client ID et Client Secret

1. Accédez à la [page de connexion de Productboard](#), saisissez votre adresse e-mail et votre mot de passe, puis choisissez Log me in.
2. Pour enregistrer une nouvelle OAuth2 application avec votre compte Productboard, rendez-vous sur la page [Productboard](#).
3. Remplissez les champs obligatoires et sélectionnez les étendues nécessaires pour chaque entité à laquelle vous souhaitez accéder.

 Note

Vous avez choisi les quatre étendues suivantes, qui sont obligatoires pour les six entités prises en charge.

4. L'URL de redirection doit avoir le format suivant : `https://ap-southeast-2\\.console\\.aws\\.amazon\\.com`

 Note

Les redirections Appflow URLs sont susceptibles d'être modifiées. Une fois disponible, veuillez mettre à jour la redirection URLs pour la AWS Glue plateforme.

5. L'ID client et le secret du client seront désormais visibles. Copiez-les et enregistrez-les dans un endroit sûr.

6. Vous pouvez configurer et vérifier OAuth2 en suivant les étapes décrites dans la section [Comment intégrer à Productboard via la documentation destinée aux OAuth2 développeurs](#).

Limites

Les limites du connecteur Productboard sont les suivantes :

- Productboard ne prend en charge ni le partitionnement basé sur les champs ni sur le partitionnement basé sur les enregistrements.

Connexion à QuickBooks

QuickBooks est une application comptable de premier plan pour les petites et moyennes entreprises. QuickBooks les applications comptables remontent aux années 1980 en tant que l'un des premiers produits d'Intuit. Il s'agissait donc à l'origine d'un logiciel de bureau. Aujourd'hui, QuickBooks propose plusieurs applications comptables et financières commerciales sous forme de logiciels installables et de logiciels SaaS basés sur le cloud. En tant qu'utilisateur QuickBooks, vous pouvez vous connecter AWS Glue à votre QuickBooks compte. Vous pouvez ensuite l'utiliser QuickBooks comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre QuickBooks des AWS services ou d'autres applications prises en charge.

Rubriques

- [AWS Glue support pour QuickBooks](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration QuickBooks](#)
- [Configuration des QuickBooks connexions](#)
- [Lecture à partir d' QuickBooks entités](#)
- [QuickBooks options de connexion](#)
- [Limitations et remarques relatives au QuickBooks connecteur](#)

AWS Glue support pour QuickBooks

AWS Glue prend en charge QuickBooks les éléments suivants :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données à partir de QuickBooks.

Soutenu en tant que cible ?

Non.

Versions QuickBooks d'API prises en charge

Les versions QuickBooks d'API suivantes sont prises en charge :

- v3

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources

spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration QuickBooks

Avant de pouvoir AWS Glue transférer des données depuis QuickBooks, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Tu as un QuickBooks compte.
- Votre QuickBooks compte est activé pour accéder à l'API.

Pour plus d'informations, consultez les rubriques suivantes de la QuickBooks documentation :

- [Créez un compte Intuit](#)
- [Créez et commencez à développer votre application](#)

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre QuickBooks compte. Pour les connexions classiques, vous n'avez rien d'autre à faire dans QuickBooks.

Configuration des QuickBooks connexions

QuickBooks prend en charge le type de subvention `AUTHORIZATION_CODE` pour. OAuth2 Le type de subvention détermine le mode de AWS Glue communication avec QuickBooks lequel vous pouvez demander l'accès à vos données.

- Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers un serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console.

- Les utilisateurs peuvent toujours choisir de créer leur propre application connectée QuickBooks et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés QuickBooks vers pour se connecter et autoriser AWS Glue l'accès à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- Pour consulter QuickBooks la documentation publique sur la création d'une application connectée pour le OAuth flux de code d'autorisation, voir [Configuration OAuth 2.0](#).

Pour configurer une QuickBooks connexion, procédez comme suit :

1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez QuickBooks.
 - b. Fournissez l'URL de l'instance et l'ID d'entreprise de l' QuickBooks instance à laquelle vous souhaitez vous connecter.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.

e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.

2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture à partir d' QuickBooks entités

Prérequis

Un QuickBooks objet que vous aimeriez lire.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Compte	Oui	Oui	Oui	Oui	Oui
Bill	Oui	Oui	Oui	Oui	Oui
Informations sur l'entreprise	Non	Non	Non	Oui	Non
Client	Oui	Oui	Oui	Oui	Oui
Employé	Oui	Oui	Oui	Oui	Oui
Estimation	Oui	Oui	Oui	Oui	Oui
Facture	Oui	Oui	Oui	Oui	Oui
Élément	Oui	Oui	Oui	Oui	Oui
Paieement	Oui	Oui	Oui	Oui	Oui
Préférences	Non	Non	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Profits et pertes	Oui	Non	Non	Oui	Non
Agence fiscale	Oui	Oui	Oui	Oui	Oui
Vendeurs	Oui	Oui	Oui	Oui	Oui

Exemple :

```
QuickBooks_read = glueContext.create_dynamic_frame.from_options(
    connection_type="quickbooks",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v3"
    }
)
```

QuickBooks détails de l'entité et du champ :

Pour plus d'informations sur les entités et les détails des champs, voir :

- [Compte](#)
- [Bill](#)
- [CompanyInfo](#)
- [Client](#)
- [Employé](#)
- [Estimation](#)
- [Facture](#)
- [Elément](#)
- [Paielement](#)
- [Préférences](#)

- [ProfitAndLoss](#)
- [TaxAgency](#)
- [Fournisseur](#)

Requêtes de partitionnement

Partitionnement basé sur le terrain :

Dans QuickBooks, les champs Integer et DateTime datatype prennent en charge le partitionnement basé sur les champs.

Vous pouvez fournir les options supplémentaires de Spark

PARTITION_FIELD, LOWER_BOUND, UPPER_BOUND, et NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- PARTITION_FIELD: le nom du champ à utiliser pour partitionner la requête.
- LOWER_BOUND: une valeur inférieure inclusive du champ de partition choisi.

Pour le champ Datetime, nous acceptons le format d'horodatage Spark utilisé dans les requêtes SQL Spark.

Exemples de valeurs valides :

```
"2024-05-07T02:03:00.00Z"
```

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: le nombre de partitions.

Exemple :

```
QuickBooks_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="quickbooks",  
    connection_options={  
        "connectionName": "connectionName",  
        "REALMID": "12345678690123456789",  
        "ENTITY_NAME": "Account",
```

```
"API_VERSION": "v3",  
"PARTITION_FIELD": "MetaData_CreateTime"  
"LOWER_BOUND": "2023-09-07T02:03:00.000Z"  
"UPPER_BOUND": "2024-05-07T02:03:00.000Z"  
"NUM_PARTITIONS": "10"  
}
```

Partitionnement basé sur des enregistrements :

La requête d'origine est divisée en NUM_PARTITIONS plusieurs sous-requêtes qui peuvent être exécutées simultanément par les tâches Spark :

- NUM_PARTITIONS: le nombre de partitions.

Exemple :

```
QuickBooks_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="quickbooks",  
    connection_options={  
        "connectionName": "connectionName",  
        "REALMID": "1234567890123456789",  
        "ENTITY_NAME": "Bill",  
        "API_VERSION": "v3",  
        "NUM_PARTITIONS": "10"  
    }  
)
```

QuickBooks options de connexion

Les options de connexion suivantes sont disponibles pour QuickBooks :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans QuickBooks.
- INSTANCE_URL(String) - (Obligatoire) Une URL d' QuickBooks instance valide.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. QuickBooks Version de l'API Rest que vous souhaitez utiliser.
- REALM_ID(Chaîne) - Un identifiant identifiant une entreprise QuickBooks en ligne individuelle à laquelle vous envoyez des demandes.
- SELECTED_FIELDS(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.

- `FILTER_PREDICATE(String)` - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- `QUERY(String)` - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- `PARTITION_FIELD(String)` - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- `LOWER_BOUND(String)` - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- `UPPER_BOUND(String)` - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS(Entier)` - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Limitations et remarques relatives au QuickBooks connecteur

Les limitations ou remarques suivantes concernent le QuickBooks connecteur :

- Dans l'`taxAgencyAPI`, le tri par filtrage ne fonctionne pas comme prévu.

Connexion à Salesforce

Salesforce fournit un logiciel de gestion de la relation client (CRM) qui vous aide dans les domaines des ventes, du service client, du commerce électronique, etc. Si vous êtes un utilisateur de Salesforce, vous pouvez vous connecter AWS Glue à votre compte Salesforce. Vous pouvez ensuite utiliser Salesforce comme source de données ou destination dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre Salesforce et les AWS services ou autres applications prises en charge.

Rubriques

- [AWS Glue support pour Salesforce](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Salesforce](#)
- [Appliquer le profil d'administrateur système](#)
- [Configuration des connexions Salesforce](#)
- [Lecture depuis Salesforce](#)
- [Écrire à Salesforce](#)

- [Options de connexion Salesforce](#)
- [Limitations du connecteur Salesforce](#)
- [Configuration du flux de code d'autorisation pour Salesforce](#)
- [Configurer le OAuth flux de porteurs JWT pour Salesforce](#)

AWS Glue support pour Salesforce

AWS Glue prend en charge Salesforce comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Salesforce.

Soutenu en tant que cible ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour écrire des enregistrements dans Salesforce.

Versions d'API Salesforce prises en charge

Les versions suivantes de l'API Salesforce sont prises en charge

- v58.0
- v59.0
- v60.0

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique IAM suivant décrit les autorisations requises pour créer, gérer et utiliser des connexions Salesforce dans les tâches AWS Glue ETL. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
```

```

        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
    ],
    "Resource": "*"
}
]
}

```

Vous pouvez également utiliser les politiques IAM suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Si vous fournissez des options réseau lors de la création d'une connexion Salesforce, les actions suivantes doivent également être incluses dans le rôle IAM :

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
    }
  ],
}

```

```
        "Resource": "*"
    }
  ]
}
```

Pour les connexions Salesforce sans ETL, consultez la section Prérequis [sans ETL](#).

Pour les connexions Salesforce sans ETL, consultez la section Prérequis [sans ETL](#).

Configuration de Salesforce

Avant de pouvoir transférer des données AWS Glue vers ou depuis Salesforce, vous devez répondre aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un compte Salesforce.
- Votre compte Salesforce est activé pour accéder à l'API. L'accès aux API est activé par défaut pour les éditions Enterprise, Unlimited, Developer et Performance.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Salesforce. AWS Glue gère les autres exigences avec l'application connectée AWS gérée.

L'application connectée AWS gérée pour Salesforce

L'application connectée AWS gérée vous permet de créer une connexion Salesforce en moins d'étapes. Dans Salesforce, une application connectée est un framework qui autorise des applications externes, par exemple AWS Glue, à accéder à vos données Salesforce à l'aide de la OAuth version 2.0. Pour utiliser l'application connectée AWS gérée, créez une connexion Salesforce à l'aide de la AWS Glue console. Lorsque vous configurez la connexion, définissez le OAuth type d'autorisation sur Code d'autorisation et laissez la case Utiliser une application client AWS gérée cochée.

Lorsque vous enregistrez la connexion, vous serez redirigé vers Salesforce pour vous connecter et approuver AWS Glue l'accès à votre compte Salesforce.

Appliquer le profil d'administrateur système

Dans Salesforce, suivez les étapes pour appliquer le profil d'administrateur système :

1. Dans Salesforce, accédez à Paramètres > Applications connectées > OAuth Utilisation des applications connectées.
2. Dans la liste des applications connectées, recherchez AWS Glue et choisissez Installer. Si nécessaire, choisissez Débloquer.
3. Accédez à Paramètres > Gérer les applications connectées, puis choisissez AWS Glue. Sous OAuth Politiques, choisissez Administrateur, les utilisateurs approuvés sont préautorisés et sélectionnez le profil d'administrateur système. Cette action restreint l'accès aux AWS Glue seuls utilisateurs possédant le profil d'administrateur système.

Appliquer le profil d'administrateur système

Dans Salesforce, suivez les étapes pour appliquer le profil d'administrateur système :

1. Dans Salesforce, accédez à Paramètres > Applications connectées > OAuth Utilisation des applications connectées.
2. Dans la liste des applications connectées, recherchez AWS Glue et choisissez Installer. Si nécessaire, choisissez Débloquer.
3. Accédez à Paramètres > Gérer les applications connectées, puis choisissez AWS Glue. Sous OAuth Politiques, choisissez Administrateur, les utilisateurs approuvés sont préautorisés et sélectionnez le profil d'administrateur système. Cette action restreint l'accès aux AWS Glue seuls utilisateurs possédant le profil d'administrateur système.

Configuration des connexions Salesforce

Pour configurer une connexion Salesforce :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour le type de subvention JWT_TOKEN, le secret doit contenir la clé JWT_TOKEN avec sa valeur.
 - b. Pour le type de AuthorizationCode subvention :
 - i. Pour une application connectée AWS gérée, un secret vide ou un secret avec une valeur temporaire doit être fourni.
 - ii. Pour une application connectée gérée par le client, le secret doit contenir l'application connectée Consumer Secret avec USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET comme clé.

- c. Remarque : Vous devez créer un secret pour votre connexion dans AWS Glue.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Salesforce.
 - b. Indiquez l'INSTANCE_URL de l'instance Salesforce à laquelle vous souhaitez vous connecter.
 - c. Fournissez l'environnement Salesforce.
 - d. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- e. Sélectionnez le type de OAuth2 subvention que vous souhaitez utiliser pour les connexions. Le type de subvention détermine le mode AWS Glue de communication avec Salesforce pour demander l'accès à vos données. Votre choix influe sur les exigences que vous devez respecter avant de créer la connexion. Vous pouvez choisir l'un des types suivants :
 - Type de subvention JWT_BEARER : ce type de subvention fonctionne bien pour les scénarios d'automatisation car il permet de créer un jeton Web JSON (JWT) dès le départ avec les autorisations d'un utilisateur particulier dans l'instance Salesforce. Le créateur contrôle la durée de validité du JWT. AWS Glue est capable d'utiliser le JWT pour obtenir un jeton d'accès qui est utilisé pour appeler Salesforce APIs.

Ce flux nécessite que l'utilisateur ait créé une application connectée dans son instance Salesforce qui permet d'émettre des jetons d'accès basés sur JWT pour les utilisateurs.

Pour plus d'informations sur la création d'une application connectée pour le OAuth flux porteur JWT, voir [OAuth 2.0 JWT bearer](#) flow pour l'intégration. server-to-server Pour configurer le flux de porteurs JWT avec l'application connectée Salesforce, consultez. [Configurer le OAuth flux de porteurs JWT pour Salesforce](#)

- Type de subvention AUTHORIZATION_CODE : Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. L'utilisateur qui crée une connexion peut par défaut s'appuyer sur une application AWS Glue connectée (application client AWS Glue gérée) dans laquelle il n'a pas besoin de fournir d'informations OAuth connexes, à l'exception de l'URL de son instance Salesforce. La AWS Glue console redirige l'utilisateur vers Salesforce où il doit se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Salesforce.

Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans Salesforce et de fournir leur propre identifiant client et leur secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Salesforce pour se connecter et autoriser AWS Glue l'accès à leurs ressources.

Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.

Pour plus d'informations sur la création d'une application connectée pour le OAuth flux de code d'autorisation, consultez [the section called "Configuration du flux de code d'autorisation pour Salesforce"](#).

- f. Sélectionnez `secretName` celui que vous souhaitez utiliser pour cette connexion AWS Glue afin de stocker les jetons OAuth 2.0.
 - g. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.
 4. Si vous fournissez des options réseau, accordez également au rôle IAM les autorisations suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
```

```

        "Action": [
            "ec2:CreateNetworkInterface",
            "ec2:DescribeNetworkInterface",
            "ec2>DeleteNetworkInterface",
        ],
        "Resource": "*"
    }
]
}

```

Configuration des connexions Salesforce avec la AWS CLI

Vous pouvez créer des connexions Salesforce à l'aide de la AWS CLI :

```

aws glue create-connection --connection-input \
"{\"Name\": \"salesforce-conn1\", \"ConnectionType\": \"SALESFORCE\",
\"ConnectionProperties\": {\"ROLE_ARN\": \"arn:aws:iam::123456789012:role/glue-role\",
\"INSTANCE_URL\": \"https://example.my.salesforce.com\"}, \"ValidateCredentials\": true,
\"AuthenticationConfiguration\": {\"AuthenticationType\": \"OAUTH2\", \"SecretArn\":
\"arn:aws:secretsmanager:us-east-1:123456789012:secret:salesforce-conn1-secret-IAMcdk
\", \"OAuth2Properties\": {\"OAuth2GrantType\": \"JWT_BEARER\", \"TokenUrl\": \"https://
login.salesforce.com/services/oauth2/token\"}}}" \
--endpoint-url https://glue.us-east-1.amazonaws.com \
--region us-east-1

```

Lecture depuis Salesforce

Prérequis

Un Salesforce sObject dont vous aimeriez lire un extrait. Vous aurez besoin du nom de l'objet tel que Account ou Case ou Opportunity.

Exemple :

```

salesforce_read = glueContext.create_dynamic_frame.from_options(
    connection_type="salesforce",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v60.0"
    }
)

```

Requêtes de partitionnement

Vous pouvez fournir les options supplémentaires de Spark

`PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, et `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur de limite inférieure inclusive du champ de partition choisi.

Pour les champs Date ou Horodatage, le connecteur accepte le format d'horodatage Spark utilisé dans les requêtes SQL Spark.

Exemples de valeurs valides :

```
"TIMESTAMP \"1707256978123\""
```

```
"TIMESTAMP '2018-01-01 00:00:00.000 UTC'"
```

```
"TIMESTAMP \"2018-01-01 00:00:00 Pacific/Tahiti\""
```

```
"TIMESTAMP \"2018-01-01 00:00:00\""
```

```
"TIMESTAMP \"-123456789\" Pacific/Tahiti"
```

```
"TIMESTAMP \"1702600882\""
```

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`: le nombre de partitions.
- `TRANSFER_MODE`: prend en charge deux modes : `SYNC` et `ASYNC`. La valeur par défaut est `SYNC`. Lorsqu'elle est définie sur `ASYNC`, la requête Bulk API 2.0 sera utilisée pour le traitement.

Exemple :

```
salesforce_read = glueContext.create_dynamic_frame.from_options(
    connection_type="salesforce",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v60.0",
        "PARTITION_FIELD": "SystemModstamp",
        "LOWER_BOUND": "TIMESTAMP '2021-01-01 00:00:00 Pacific/Tahiti'",
        "UPPER_BOUND": "TIMESTAMP '2023-01-10 00:00:00 Pacific/Tahiti'",
        "NUM_PARTITIONS": "10",
```

```
"TRANSFER_MODE": "ASYNC"  
}
```

Écrire à Salesforce

Prérequis

Un Salesforce sObject auquel vous souhaitez écrire. Vous aurez besoin du nom de l'objet tel que Account ou Case ou Opportunity.

Le connecteur Salesforce prend en charge quatre opérations d'écriture :

- INSERT
- UPSERT
- UPDATE
- DELETE

Lors de l'utilisation de l'opération d'UPSERT d'écriture, l'ID_FIELD_NAME Option doit être fournie pour spécifier le champ d'ID externe pour les enregistrements.

Vous pouvez également ajouter des options de connexion :

- TRANSFER_MODE: Supporte deux modes : SYNC et ASYNC. La valeur par défaut est SYNC. Lorsqu'il est défini sur ASYNC, Bulk API 2.0 Ingest sera utilisé pour le traitement.
- FAIL_ON_FIRST_ERROR: La valeur par défaut est FALSE, ce qui signifie que la AWS Glue tâche continuera à traiter toutes les données même si certains enregistrements d'écriture ont échoué. Lorsqu'elle est définie sur TRUE, la AWS Glue tâche échouera en cas d'échec des enregistrements d'écriture et le traitement ne sera pas poursuivi.

Exemple

```
salesforce_write = glueContext.write_dynamic_frame.from_options(  
    frame=frameToWrite,  
    connection_type="salesforce",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "Account",  
        "API_VERSION": "v60.0",  
        "WRITE_OPERATION": "INSERT",
```

```
"TRANSFER_MODE": "ASYNC",  
"FAIL_ON_FIRST_ERROR": "true"  
}
```

Options de connexion Salesforce

Les options de connexion suivantes sont prises en charge pour le connecteur Salesforce :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Salesforce.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Salesforce Rest que vous souhaitez utiliser.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.

Lorsque vous fournissez un prédicat de filtre, seul l'ANDopérateur est pris en charge. D'autres opérateurs tels que OR et ne IN sont pas pris en charge actuellement.

- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.
- **IMPORT_DELETED_RECORDS**(String) - Par défaut : FALSE. Utilisé pour lire. Pour obtenir les enregistrements supprimés lors de la requête.
- **WRITE_OPERATION**(String) - Par défaut : INSERT. Utilisé pour écrire. La valeur doit être INSERT, UPDATE, UPSERT, DELETE.
- **ID_FIELD_NAMES**(String) - Par défaut : null. Nécessaire pour UPDATE et UPSERT.

Limitations du connecteur Salesforce

Les limites du connecteur Salesforce sont les suivantes :

- Nous prenons uniquement en charge Spark SQL et Salesforce SOQL n'est pas pris en charge.
- Les signets de tâche ne sont pas pris en charge.
- Les noms de champs Salesforce distinguent les majuscules et minuscules. Lorsque vous écrivez dans Salesforce, les données doivent correspondre au cadre des champs définis dans Salesforce.

Configuration du flux de code d'autorisation pour Salesforce

Reportez-vous à la documentation publique de Salesforce pour activer le flux de code d'autorisation OAuth 2.0.

Pour configurer l'application connectée :

1. Cochez la case Activer OAuth les paramètres.
2. Dans le champ de texte URL de rappel, entrez une ou plusieurs redirections URLs pour AWS Glue.

URLs Les redirections ont le format suivant :

`https ://region.console.aws.amazon. com/gluestudio/oauth`

Dans cette URL, la région est le code de la AWS région que vous utilisez AWS Glue pour transférer des données depuis Salesforce. Par exemple, le code de la région USA Est (Virginie du Nord) est `us-east-1`. Pour cette région, l'URL est la suivante :

`https://us-east-1.console.aws.amazon.com/gluestudio/oauth`

Pour les AWS régions qui les prennent AWS Glue en charge et leurs codes, voir les [AWS Glue points de terminaison et les quotas](#) dans la référence AWS générale.

3. Cochez la case Exiger le secret pour le flux du serveur Web.
4. Dans la liste OAuth des étendues disponibles, ajoutez les étendues suivantes :
 - Gérez les données utilisateur via APIs (api)
 - Accéder aux autorisations personnalisées (custom_permissions)
 - Accédez au service d'URL d'identité (identifiant, profil, e-mail, adresse, téléphone)
 - Accédez à des identifiants utilisateur uniques (openid)
 - Exécuter des requêtes à tout moment (refresh_token, offline_access)
5. Définissez la politique du jeton d'actualisation pour l'application connectée afin que le jeton d'actualisation soit valide jusqu'à sa révocation. Dans le cas contraire, vos tâches échoueront à

l'expiration de votre jeton d'actualisation. Pour plus d'informations sur la façon de vérifier et de modifier la politique des jetons d'actualisation, consultez la section [Gérer les politiques d' OAuth accès pour une application connectée](#) dans la documentation Salesforce.

Configurer le OAuth flux de porteurs JWT pour Salesforce

Reportez-vous à la documentation publique de Salesforce pour activer server-to-server l'intégration avec les [jetons Web JSON OAuth 2.0](#).

Une fois que vous avez créé un JWT et configuré l'application connectée de manière appropriée dans Salesforce, vous pouvez créer une nouvelle connexion Salesforce avec la JWT_TOKEN clé définie dans votre secret Secrets Manager. Définissez le type de OAuth subvention sur JWT Bearer Token lors de la création de la connexion.

Connexion à Salesforce Marketing Cloud

Salesforce Marketing Cloud est un fournisseur de logiciels d'automatisation et d'analyse marketing pour le marketing par e-mail, mobile, social et en ligne. Elle propose également des services de conseil et de mise en œuvre. En tant qu'utilisateur de Salesforce Marketing Cloud, vous pouvez vous connecter AWS Glue à votre compte Salesforce Marketing Cloud. Vous pouvez ensuite utiliser Salesforce Marketing Cloud comme source de données ou destination dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre Salesforce Marketing Cloud et les AWS services ou autres applications prises en charge.

Rubriques

- [AWS Glue support pour Salesforce Marketing Cloud](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Salesforce Marketing Cloud](#)
- [Configuration des connexions Salesforce Marketing Cloud](#)
- [Lecture à partir d'entités Salesforce Marketing Cloud](#)
- [Écrire aux entités Salesforce Marketing Cloud](#)
- [Options de connexion à Salesforce Marketing Cloud](#)
- [Limitations et remarques relatives au connecteur Salesforce Marketing Cloud](#)

AWS Glue support pour Salesforce Marketing Cloud

AWS Glue prend en charge Salesforce Marketing Cloud comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données depuis Salesforce Marketing Cloud.

Soutenu en tant que cible ?

Non

Versions de l'API Salesforce Marketing Cloud prises en charge

Les versions suivantes de l'API Salesforce Marketing Cloud sont prises en charge :

- v1

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Salesforce Marketing Cloud

Avant de pouvoir AWS Glue transférer des données depuis Salesforce Marketing Cloud, vous devez répondre aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous possédez un compte Salesforce Marketing Cloud. Pour de plus amples informations, veuillez consulter [Création d'un compte Salesforce Marketing Cloud](#).
- Votre compte Salesforce Marketing Cloud est activé pour accéder à l'API. L'accès aux API est activé par défaut pour les éditions Enterprise, Unlimited, Developer et Performance.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Salesforce Marketing Cloud. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Salesforce Marketing Cloud.

Création d'un compte Salesforce Marketing Cloud

Pour Salesforce Marketing Cloud, vous devez contacter le fournisseur pour créer un compte. Si vous ou votre entreprise êtes associé à Salesforce, contactez votre responsable de compte Salesforce pour demander une licence Salesforce Marketing Cloud. Sinon, vous pouvez demander le contact d'un représentant Salesforce comme suit :


1. Accédez à <https://www.salesforce.com/in/products/marketing-cloud/overview/> et choisissez S'inscrire.
2. Sélectionnez le lien Contactez-nous en haut à droite de la page.
3. Entrez les informations requises dans le formulaire et choisissez Contactez-moi.

Un représentant de Salesforce vous contactera pour discuter de vos besoins.

Création d'un projet et informations d'identification OAuth 2.0

Pour obtenir un projet et des informations d'identification OAuth 2.0 :


1. Connectez-vous à votre [instance Salesforce Marketing Cloud](#) à l'aide de votre nom d'utilisateur et de votre mot de passe et authentifiez-vous à l'aide de votre numéro de téléphone portable enregistré.
2. Cliquez sur votre profil en haut à droite, puis sur Configuration.
3. Sous Outils de plate-forme, choisissez Applications, puis Packages installés.



4. Sur la page Packages installés, cliquez sur Nouveau dans le coin supérieur droit. Entrez le nom et la description du package.

Enregistrez le package. Une fois le package enregistré, vous pouvez consulter les détails du package.

5. Sur la page Détails du package, dans la section Composant, choisissez Ajouter un composant.



6. Sélectionnez le type de composant « Intégration d'API » et cliquez sur Suivant.
7. Sélectionnez le type d'intégration « Server-à-serveur » (qui possède le type d' OAuth autorisation des informations d'identification du client) et cliquez sur Suivant.
8. Ajoutez les étendues en fonction de vos besoins et cliquez sur Enregistrer.

Configuration des connexions Salesforce Marketing Cloud

Salesforce Marketing Cloud prend en charge le type de subvention CLIENT CREDENTIALS pour OAuth2.

- Ce type de subvention est considéré comme une OAuth version 2.0 bidimensionnelle car il est utilisé par les clients pour obtenir un jeton d'accès en dehors du contexte d'un utilisateur. AWS Glue est capable d'utiliser l'ID client et le secret du client pour authentifier le Salesforce Marketing Cloud, APIs qui sont fournis par les services personnalisés que vous définissez.

- Chaque service personnalisé appartient à un utilisateur utilisant uniquement l'API, qui dispose d'un ensemble de rôles et d'autorisations autorisant le service à effectuer des actions spécifiques. Un jeton d'accès est associé à un seul service personnalisé.
- Ce type d'autorisation donne lieu à un jeton d'accès de courte durée qui peut être renouvelé en appelant un point de terminaison d'identité.
- Pour consulter la documentation publique de Salesforce Marketing Cloud pour OAuth 2.0 avec les informations d'identification du client, voir [Configurer votre environnement de développement pour les packages améliorés](#).

Pour configurer une connexion Salesforce Marketing Cloud :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir le secret du consommateur de l'application connectée avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
 - b. Remarque : Vous devez créer un secret pour vos connexions dans AWS Glue.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Salesforce Marketing Cloud.
 - b. Indiquez le Subdomain Endpoint Salesforce Marketing Cloud auquel vous souhaitez vous connecter.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
    }
  ],
}
```

```

        "Resource": "*"
    }
]
}

```

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture à partir d'entités Salesforce Marketing Cloud

Prérequis

Un objet Salesforce Marketing Cloud dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet tel que `Activity` ou `Campaigns`. Le tableau suivant indique les entités prises en charge.

Entités prises en charge pour la source :

Entité	utilisateur	Peut être filtré	Limite de supports	Supporte Order by	Supporte SELECT *	Supporte le partitionnement
Rappel de notification d'événement	REST	Non	Non	Non	Oui	Non
Liste de graines	REST	Non	Oui	Non	Oui	Non
Configuration	REST	Oui	Oui	Non	Oui	Non
Vérification de domaine	REST	Oui	Oui	Oui	Oui	Non

Entité	utilisateur	Peut être filtré	Limite de supports	Supporte Order by	Supporte SELECT *	Supporte le partitionnement
Balises imbriquées d'objets	REST	Oui	Non	Non	Oui	Non
Contact	REST	Non	Oui	Non	Oui	Non
Abonnement aux notifications d'événements	REST	Non	Non	Non	Oui	Non
Messagerie	REST	Non	Oui	Non	Oui	Non
Activité	SOAP	Non	Non	Non	Oui	Oui
Événement Bounce	SOAP	Non	Non	Non	Oui	Oui
Cliquez sur Événement	SOAP	Non	Non	Non	Oui	Oui
Zone de contenu	SOAP	Non	Non	Non	Oui	Oui
Extension de données	SOAP	Non	Oui	Non	Oui	Oui
E-mails	SOAP	Non	Oui	Non	Oui	Oui

Entité	utilisateur	Peut être filtré	Limite de supports	Supporte Order by	Supporte SELECT *	Supporte le partitionnement
Événement de transfert d'e-mail	SOAP	Non	Oui	Non	Oui	Oui
Transférer un e-mail OptInEvent	SOAP	Non	Oui	Non	Oui	Oui
Lien	SOAP	Non	Oui	Non	Oui	Oui
Envoyer le lien	SOAP	Non	Oui	Non	Oui	Oui
Liste	SOAP	Non	Oui	Non	Oui	Oui
Abonné à la liste	SOAP	Non	Oui	Non	Oui	Oui
Événement non envoyé	SOAP	Non	Oui	Non	Oui	Oui
Événement ouvert	SOAP	Non	Oui	Non	Oui	Oui
Envoyer	SOAP	Non	Oui	Non	Oui	Oui
Événement envoyé	SOAP	Non	Oui	Non	Oui	Oui
Subscriber	SOAP	Non	Oui	Non	Oui	Oui
Événement d'enquête	SOAP	Non	Oui	Non	Oui	Oui

Entité	utilisateur	Peut être filtré	Limite de supports	Supporte Order by	Supporte SELECT *	Supporte le partitionnement
Événement Unsub	SOAP	Non	Oui	Non	Oui	Oui
Événements d'audit	REST	Non	Oui	Oui	Oui	Non
Campagnes	REST	Non	Oui	Oui	Oui	Non
Interactions	REST	Non	Oui	Oui	Oui	Non
Ressources de contenu	REST	Non	Oui	Oui	Oui	Non

Exemple pour REST :

```
salesforcemarketingcloud _read = glueContext.create_dynamic_frame.from_options(
    connection_type="salesforcemarketingcloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Campaigns",
        "API_VERSION": "v1",
        "INSTANCE_URL": "https://*****.rest.marketingcloudapis.com"
    }
)
```

Exemple pour SOAP :

```
salesforcemarketingcloud _read = glueContext.create_dynamic_frame.from_options(
    connection_type="salesforcemarketingcloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Activity",
        "API_VERSION": "v1",
        "INSTANCE_URL": "https://*****.soap.marketingcloudapis.com"
    }
)
```


}

Détails de l'entité et du champ Salesforce Marketing Cloud :

Les tableaux suivants décrivent les entités Salesforce Marketing Cloud. Il existe des entités REST avec des métadonnées statiques et des entités SOAP avec des métadonnées dynamiques.

Entités REST avec métadonnées statiques :

Entité	Champ	Type de données	Opérateurs pris en charge
Rappel de notification d'événement	ID de rappel	Chaîne	
	Nom du rappel	Chaîne	
	url	Chaîne	
	maxBatchSize	Entier	
	status	Chaîne	
	Motif du statut	Chaîne	
Liste de graines	id	Chaîne	
	name	Chaîne	
	description	Chaîne	
	activeSeedCount	Entier	
Configuration	Clé client	Chaîne	
	name	Chaîne	
	description	Chaîne	
	Type de lieu	Chaîne	'='
	awsFileTransferLocation	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
Vérification du domaine	ID d'entreprise	Entier	
	status	Chaîne	'='
	Type de domaine	Chaîne	'='
	ID de membre	Entier	
	emailSendTime	DateTime	
	domaine	Chaîne	
	est envoyable	Booléen	
Balises imbriquées d'objets	id	Entier	
	Date de modification	DateTime	
	balises	Liste	
	name	Chaîne	
	description	Chaîne	
	Identifiant du parent	Entier	
Contact	values	Liste	
Abonnement aux notifications d'événements	Nom de l'abonnement	Chaîne	
	ID de rappel	Chaîne	
	Nom du rappel	Chaîne	
	eventCategoryTypes	Liste	
	filtres	Liste	
	url	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	maxBatchSize	Entier	
	ID d'abonnement	Chaîne	
	status	Chaîne	
	Motif du statut	Chaîne	
Messagerie	Délai de livraison	DateTime	
	id	Chaîne	
	messageld	Chaîne	
	status	Chaîne	
	to	Struct	
Interactions	status	Chaîne	'='
	id	Chaîne	
	key	Chaîne	
	name	Chaîne	
	lastPublishedDate	DateTime	
	description	Chaîne	
	version	Entier	
	workflowApiVersion	Entier	
	createdDate	DateTime	
	Date de modification	DateTime	
	but	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
	stats	Struct	
	Mode d'entrée	Chaîne	
	defaults	Struct	
	Mode d'exécution	Struct	
	ID de définition	Chaîne	
Ressources de contenu	id	Entier	
	Clé client	Chaîne	
	objectId	Chaîne	
	contentType	Chaîne	
	Type d'actif	Struct	
	name	Chaîne	
	description	Chaîne	
	owner	Struct	
	createdDate	DateTime	
	Créé par	Struct	
	Date de modification	DateTime	
	Modifié par	Struct	
	la vignette	Struct	
	category	Struct	
	méta	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
	vues	Struct	
	Vues disponibles	Struct	
	data	Struct	
	Données héritées	Struct	
	Version du modèle	Entier	
	Version	Entier	
	Locked (Verrouillée)	Booléen	
	FileProperties	Struct	
	Balises	Liste	
	Contenu	Chaîne	
	Conception	Chaîne	
	SuperContent	Chaîne	
	CustomFields	Struct	
	Blocs	Struct	
	MinBlocks	Entier	
	MaxBlocks	Entier	
	Canaux	Struct	
	AllowedBlocks	Liste	
	Emplacements	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
	BusinessUnitAvailability	Struct	
	Partage de propriétés	Struct	
	Partage de propriétés. Partagé avec	Struct	
	Propriétés de partage. Type de partage	Chaîne	
	Modèle	Struct	
	Fichier	Chaîne	
	GenerateFrom	Chaîne	
Événements d'audit	id	Entier	
	createdDate	DateTime	
	ID de membre	Entier	
	ID d'entreprise	Entier	
	employé	Struct	
	objectType	Struct	
	fonctionnement	Struct	
	objet	Struct	
	ID de transaction	Chaîne	
Campagnes	id	Entier	
	createdDate	DateTime	

Entité	Champ	Type de données	Opérateurs pris en charge
	Date de modification	DateTime	
	name	Chaîne	
	description	Chaîne	
	Code de campagne	Chaîne	
	color	Chaîne	
	favori	Booléen	

Entités SOAP avec métadonnées dynamiques :

Entité	Type de données	Opérateurs pris en charge
Activité	Chaîne	COMME, !=, =
	Struct	
	Entier	!=, =, >=, <=, <, >
	Double	!=, =, >=, <=, <, >
	Booléen	!=, =
	DateTime	>=, <=, <, >, =, ENTRE
Événement Bounce	Entier	!=, =, >=, <=, <, >
	DateTime	>=, <=, <, >, =, ENTRE
	Chaîne	COMME, !=, =
	Struct	
Cliquez sur Événement	Entier	!=, =, >=, <=, <, >

Entité	Type de données	Opérateurs pris en charge
Zone de contenu	DateTime	>=, <=, <, >, =, ENTRE
	Chaîne	COMME, !=, =
	Struct	
	Struct	
	Chaîne	COMME, !=, =
	Entier	!=, =, >=, <=, <, >
	DateTime	>=, <=, <, >, =, ENTRE
Extension de données	Booléen	!=, =
	DateTime	>=, <=, <, >, =, ENTRE
E-mails	Chaîne	COMME, !=, =
	Entier	!=, =, >=, <=, <, >
	Chaîne	COMME, !=, =
	DateTime	>=, <=, <, >, =, ENTRE
	Booléen	!=, =
Événement de transfert d'e-mail	Struct	
	Entier	!=, =, >=, <=, <, >
	Chaîne	COMME, !=, =
	DateTime	>=, <=, <, >, =, ENTRE
Courrier électronique transféré OptInEvent	Struct	
	Entier	!=, =, >=, <=, <, >

Entité	Type de données	Opérateurs pris en charge
	Chaîne	COMME, !=, =
	DateTime	>=, <=, <, >, =, ENTRE
	Struct	
Lien	Entier	!=, =, >=, <=, <, >
Envoyer le lien	Entier	!=, =, >=, <=, <, >
	Chaîne	COMME, !=, =
	Double	!=, =, >=, <=, <, >
Liste	Entier	!=, =, >=, <=, <, >
	Chaîne	COMME, !=, =
	DateTime	>=, <=, <, >, =, ENTRE
	Struct	
Abonné à la liste	Entier	!=, =, >=, <=, <, >
	Chaîne	COMME, !=, =
	DateTime	>=, <=, <, >, =, ENTRE
	Struct	
Événement non envoyé	Entier	!=, =, >=, <=, <, >
	Chaîne	COMME, !=, =
	DateTime	>=, <=, <, >, =, ENTRE
	Struct	
Événement ouvert	Entier	!=, =, >=, <=, <, >

Entité	Type de données	Opérateurs pris en charge
	Chaîne	COMME, !=, =
	DateTime	>=, <=, <, >, =, ENTRE
	Struct	
	Entier	!=, =, >=, <=, <, >
	Booléen	!=, =
Envoyer	Chaîne	COMME, !=, =
	DateTime	>=, <=, <, >, =, ENTRE
	Booléen	!=, =
	Struct	
Événement envoyé	Entier	!=, =, >=, <=, <, >
	Chaîne	COMME, !=, =
	DateTime	>=, <=, <, >, =, ENTRE
	Struct	
Subscriber	Entier	!=, =, >=, <=, <, >
	Chaîne	COMME, !=, =
	DateTime	>=, <=, <, >, =, ENTRE
	Struct	
Événement d'enquête	Entier	!=, =, >=, <=, <, >
	Chaîne	COMME, !=, =
	DateTime	>=, <=, <, >, =, ENTRE
	Struct	

Entité	Type de données	Opérateurs pris en charge
Événement Unsub	Entier	!=,=,>,<=<,>
	Chaîne	COMME, !=, =
	DateTime	>=, <=, <, >, =, ENTRE
	Booléen	!=, =
	Struct	

Requêtes de partitionnement

Dans Salesforce Marketing Cloud, les champs Integer et DateTime Datatype prennent en charge le partitionnement basé sur les champs.

Vous pouvez fournir les options supplémentaires de Spark

`PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, et `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur limite inférieure inclusive du champ de partition choisi.

Pour le champ d'horodatage, nous acceptons le format d'horodatage Spark utilisé dans les requêtes SQL Spark.

Exemples de valeurs valides :

```
"2024-05-07T02:03:00.00Z"
```

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`: le nombre de partitions.

Exemple :

```
salesforcemarketingcloud_read = glueContext.create_dynamic_frame.from_options(
```

```
connection_type="salesforcemarketingcloud",
connection_options={
    "connectionName": "connectionName",
    "ENTITY_NAME": "ListSubscriber",
    "API_VERSION": "v1",
    "PARTITION_FIELD": "CreatedDate"
    "LOWER_BOUND": "2023-09-07T02:03:00.000Z"
    "UPPER_BOUND": "2024-05-07T02:03:00.000Z"
    "NUM_PARTITIONS": "10"
}
```

Écrire aux entités Salesforce Marketing Cloud

Prérequis

- Un objet Salesforce Marketing auquel vous souhaitez écrire. Vous devrez spécifier le nom de l'objet tel que List Campaigns ou l'une des autres entités décrites dans le tableau ci-dessous.
- Le connecteur Salesforce Marketing Cloud prend en charge trois opérations d'écriture :
 - INSERT
 - UPSERT
 - UPDATE

Lorsque vous utilisez les opérations UPSERT d'écriture UPDATE et d'écriture, vous devez fournir la ID_FIELD_NAMES possibilité de spécifier le champ d'ID externe pour les enregistrements.

Entités prises en charge pour la destination :

Entité	Priorité	Interface (REST, SOAP, etc.)	Peut être inséré	Peut être mis à jour	Peut être bouleversé
Campagnes	P0	REST	Y- Unique	Y- Unique	N
Ressources de contenu	P0	REST	Y- Unique, en vrac	Y- Unique	N
Contact	P1	REST	Y- Unique	Y- Unique	N

Entité	Priorité	Interface (REST, SOAP, etc.)	Peut être inséré	Peut être mis à jour	Peut être bouleversé
Vérification de domaine	P1	REST	Y- Unique	Y- Unique, en vrac	N
Rappel de notification d'événement	P1	REST	Y- Unique	Y- Unique	N
Abonnement aux notifications d'événements	P1	REST	Y- Unique	Y- Unique	N
Messagerie	P1	REST	Y- Unique	N	N
Tag imbriqué dans un objet	P2	REST	Y- Unique	Y- Unique	N
Liste de graines	P1	REST	Y- Unique	Y- Unique	N
Configuration	P1	REST	Y- Unique	Y- Unique	N
Extension de données	P0	SOAP	Y- Unique	Y- Unique	Y- Unique
E-mails	P0	SOAP	Y- Unique	Y- Unique	N
Liste	P0	SOAP	Y- Unique	Y- Unique	N
Envoyer	P0	SOAP	Y- Unique	N	N
Subscriber	P0	SOAP	Y- Unique	Y- Unique	N

Exemple d'opération INSERT pour REST :

```
salesforcemarketingcloud _write = glueContext.write_dynamic_frame.from_options(  
    connection_type="salesforcemarketingcloud",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "Campaigns",  
        "API_VERSION": "v1",  
        "writeOperation" : "INSERT",  
        "INSTANCE_URL": "https://*****.rest.marketingcloudapis.com"  
    }  
)
```

Exemple d'opération INSERT pour SOAP :

```
salesforcemarketingcloud _write = glueContext.write_dynamic_frame.from_options(  
    connection_type="salesforcemarketingcloud",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "List",  
        "API_VERSION": "v1",  
        "writeOperation" : "INSERT",  
        "INSTANCE_URL": "https://*****.rest.marketingcloudapis.com"  
    }  
)
```

Exemple d'opération UPDATE pour REST :

```
salesforcemarketingcloud _write = glueContext.write_dynamic_frame.from_options(  
    connection_type="salesforcemarketingcloud",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "Campaigns",  
        "API_VERSION": "v1",  
        "writeOperation" : "UPDATE",  
        "ID_FIELD_NAMES": "id",  
        "INSTANCE_URL": "https://*****.rest.marketingcloudapis.com"  
    }  
)
```

Exemple d'opération de mise à jour pour SOAP :

```
salesforcemarketingcloud _write = glueContext.write_dynamic_frame.from_options(  
    connection_type="salesforcemarketingcloud",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "List",  

```

```

    "API_VERSION": "v1",
    "writeOperation" : "UPDATE",
    "ID_FIELD_NAMES": "id",
    "INSTANCE_URL": "https://*****.rest.marketingcloudapis.com"
}

```

Exemple d'opération UPSERT pour SOAP :

```

salesforcemarketingcloud _write = glueContext.write_dynamic_frame.from_options(
    connection_type="salesforcemarketingcloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "DataExtension/Insert-***E/6*****3",
        "API_VERSION": "v1",
        "writeOperation" : "UPSERT",
        "INSTANCE_URL": "https://*****.rest.marketingcloudapis.com"
    }
)

```

Options de connexion à Salesforce Marketing Cloud

Les options de connexion pour Salesforce Marketing Cloud sont les suivantes :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Salesforce Marketing Cloud.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de Salesforce Marketing Cloud Rest et de l'API SOAP que vous souhaitez utiliser.
- SELECTED_FIELDS(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- FILTER_PREDICATE(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- QUERY(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- PARTITION_FIELD(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- LOWER_BOUND(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- UPPER_BOUND(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

- `WRITE_OPERATION(String)` - Par défaut : `INSERT`. Utilisé pour écrire. La valeur doit être `INSERT`, `UPDATE`, `UPSERT`.
- `ID_FIELD_NAMES(String)` - Valeur par défaut : `null`. Nécessaire pour `UPDATE/UPSERT`.

Limitations et remarques relatives au connecteur Salesforce Marketing Cloud

Voici les limites ou remarques relatives au connecteur Salesforce Marketing Cloud :

- Lorsque vous utilisez un filtre sur `DateTime` un champ de type de données, vous devez transmettre la valeur au format « `yyyy-mm-dd THH:MM:SSZ` ».
- Dans `Data Preview`, la valeur du type de données booléen apparaît sous la forme d'une valeur vide.
- Pour les entités `SOAP`, vous pouvez définir un maximum de deux filtres, et pour les entités `REST`, vous ne pouvez définir qu'un seul filtre, ce qui limite les tests de partitionnement avec des filtres.
- Plusieurs comportements inattendus ont été observés du côté du SaaS : le `Link.Alias` champ de l'entité `'linksend'` ne prend pas en charge l'opérateur `CONTAINS` (par exemple, `Link.Alias CONTAINS "ViewPrivacyPolicy"`), et les opérateurs de filtre pour les entités d'extension de données (telles que `EQUALS` et `GREATER THAN`) ne renvoient pas les résultats attendus.
- L'API `ClickEvent SOAP SFMC` prend du temps pour refléter les enregistrements nouvellement créés, de sorte que les enregistrements créés récemment peuvent ne pas être immédiatement disponibles dans la réponse de l'API.

Exemple : Si vous créez 5 nouveaux `ClickEvent` enregistrements le `2025-01-10T 14:30:00` et que vous les récupérez immédiatement à l'aide de l'API `SOAP`, la réponse risque de ne pas inclure les 5 enregistrements. Les enregistrements nouvellement créés peuvent prendre jusqu'à 5 minutes pour apparaître dans la réponse de l'API. Ce délai peut également affecter à la fois la récupération des données et les exécutions planifiées.

- Deux `DateTime` formats différents : `2025-03-11T 04:46:00` (sans millisecondes) et `2025-03-11T 04:46:00.000 Z` sont pris en charge lors de l'exécution d'opérations d'écriture en (en millisecondes).
- AWS Glue
- Pour l'entité d'abonnement aux notifications d'événements, un abonnement ne peut être créé que pour une URL de rappel vérifiée, et vous pouvez avoir jusqu'à 200 abonnements par rappel.
 - Pour l'entité `Event Notification Callback`, un maximum de 50 enregistrements peuvent être créés par compte.

Connexion à Salesforce Commerce Cloud

L'API B2C Commerce est un ensemble d'instances de commerce B2C RESTful APIs permettant d'interagir avec les instances de commerce B2C. Il porte plusieurs noms différents : Salesforce Commerce API, acronyme SCAPI ou simplement Commerce API.

L'API permet aux développeurs de créer un large éventail d'applications : des vitrines complètes aux outils personnalisés pour les commerçants, en passant par l'amélioration de Business Manager. Pour tous les clients du commerce B2C, l'API est disponible sans frais supplémentaires.

L'API est divisée en deux groupes principaux APIs : Shopper APIs et Admin APIs. Au sein de chaque groupe, ils sont divisés en familles d'API et en petits groupes axés sur les fonctionnalités associées.

Rubriques

- [AWS Glue support pour Salesforce Commerce Cloud](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Salesforce Commerce Cloud](#)
- [Configuration des connexions Salesforce Commerce Cloud](#)
- [Lecture à partir d'entités Salesforce Commerce Cloud](#)
- [Référence des options de connexion Salesforce Commerce Cloud](#)
- [Limites](#)

AWS Glue support pour Salesforce Commerce Cloud

AWS Glue prend en charge Salesforce Commerce Cloud comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données depuis Salesforce Commerce Cloud.

Soutenu en tant que cible ?

Non.

Versions de l'API Salesforce Commerce Cloud prises en charge

v1.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Vous pouvez également utiliser les politiques IAM gérées suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Salesforce Commerce Cloud

Avant de pouvoir AWS Glue transférer des données depuis Salesforce Commerce Cloud, vous devez répondre aux exigences suivantes :

Configuration requise

- Vous disposez d'une application client Salesforce Commerce Cloud avec ClientID et ClientSecret.
- Votre compte Salesforce Commerce Cloud est activé pour accéder à l'API.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Salesforce Commerce Cloud. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Salesforce Commerce Cloud.

Configuration des connexions Salesforce Commerce Cloud

Salesforce Commerce Cloud prend en charge le type de subvention CLIENT CREDENTIALS pour OAuth2.

- Ce type de subvention est considéré comme un système OAuth 2.0 à deux volets car il est utilisé par les clients pour obtenir un jeton d'accès en dehors du contexte d'un utilisateur. AWS Glue est capable d'utiliser l'identifiant et le secret du client pour authentifier Salesforce Commerce Cloud, APIs qui sont fournis par des services personnalisés que vous définissez.
- Chaque service personnalisé appartient à un utilisateur utilisant uniquement l'API, qui dispose d'un ensemble de rôles et d'autorisations autorisant le service à effectuer des actions spécifiques. Un jeton d'accès est associé à un seul service personnalisé.
- Ce type d'autorisation donne lieu à un jeton d'accès de courte durée qui peut être renouvelé en appelant le point de terminaison d'identité.
- Pour plus d'informations sur la documentation de Salesforce Commerce Cloud relative à la génération des informations d'identification du client, consultez [la documentation Salesforce](#).

Pour configurer une connexion Salesforce Commerce Cloud :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes. Il est nécessaire de créer un secret pour chaque connexion dans AWS Glue.
 - a. Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec la clé USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET.
2. Dans AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 - a. Sous Connexions de données, choisissez Créer une connexion.
 - b. Lorsque vous sélectionnez une source de données, sélectionnez Salesforce Commerce Cloud.

- c. Entrez votre code abrégé, votre identifiant d'organisation et votre identifiant de site Salesforce Commerce Cloud.
- d. Sélectionnez l'URL du domaine Salesforce Commerce Cloud de votre compte Salesforce Commerce Cloud.
- e. Sélectionnez le rôle IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- f. Indiquez les OAuth champs d'application (facultatif, application client gérée par l'utilisateur) ClientId du Salesforce Commerce Cloud auquel vous souhaitez vous connecter.
 - g. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - h. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.
 4. Dans la configuration de votre AWS Glue tâche, fournissez connectionName une connexion réseau supplémentaire.

Lecture à partir d'entités Salesforce Commerce Cloud

Prérequis

- Un objet Salesforce Commerce Cloud dont vous aimeriez lire un extrait. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Assignments (affectations)	Oui	Oui	Oui	Oui	Oui
Campagnes	Oui	Oui	Oui	Oui	Oui
Catalogues	Oui	Oui	Oui	Oui	Oui
Catégories	Oui	Oui	Oui	Oui	Oui
Coupons	Oui	Oui	Oui	Oui	Oui
Chèques-cadeaux	Oui	Oui	Oui	Oui	Oui
Produits	Oui	Oui	Oui	Oui	Oui
Promotions	Oui	Oui	Oui	Oui	Oui
Groupes de code source	Oui	Oui	Oui	Oui	Oui

Exemple

```
salesforce_commerce_cloud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="SalesforceCommerceCloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "campaign",
        "API_VERSION": "v1"
    }
)
```

Détails de l'entité et des champs de Salesforce Commerce Cloud

Liste des entités :

- Missions : <https://developer.salesforce.com/docs/commerce/commerce-api/references/assignments>
- Campagnes : <https://developer.salesforce.com/docs/commerce/commerce-api/references/campaigns>
- Catalogues : <https://developer.salesforce.com/docs/commerce/commerce-api/references/catalogs>
- Catégories : [https://developer.salesforce.com/docs/commerce/commerce-api/references/catalogs?META = Catégories de recherche](https://developer.salesforce.com/docs/commerce/commerce-api/references/catalogs?META=Catégories%20de%20recherche)
- Chèques-cadeaux : <https://developer.salesforce.com/docs/commerce/commerce-api/references/gift-chèques-cadeaux>
- Produits : <https://developer.salesforce.com/docs/commerce/commerce-api/references/products>
- Promotions : <https://developer.salesforce.com/docs/commerce/commerce-api/references/promotions>
- Groupes de code source : <https://developer.salesforce.com/docs/commerce/commerce-api/references/source-code-groups>

Requêtes de partitionnement

Des options Spark supplémentaires `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, `NUM_PARTITIONS` peuvent être fournies si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur limite inférieure inclusive du champ de partition choisi.

Pour la date, nous acceptons le format de date Spark utilisé dans les requêtes SQL Spark.
Exemple de valeurs valides : "2024-02-06"

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`: nombre de partitions.

Les détails relatifs à la prise en charge des champs de partitionnement par entité sont présentés dans le tableau ci-dessous :

Entité	Champ de partitionnement	DataType
Campagnes	Dernière modification	DateTime
Campagnes	startDate	DateTime
Campagnes	endDate	DateTime
Catalogues	creationDate	DateTime
Catégories	Date de création	DateTime
Chèques-cadeaux	Identifiant du vendeur	Chaîne
Chèques-cadeaux	Date de création	DateTime
Produits	Date de création	DateTime
Produits	Dernière modification	DateTime
Groupes de code source	creationDate	DateTime
Groupes de code source	startTime	DateTime
Groupes de code source	endTime	DateTime

Exemple

```
salesforceCommerceCloud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="SalesforceCommerceCloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "coupons",
        "API_VERSION": "v1",
        "PARTITION_FIELD": "creationDate"
        "LOWER_BOUND": "2020-05-01T20:55:02.000Z"
        "UPPER_BOUND": "2024-07-11T20:55:02.000Z"
        "NUM_PARTITIONS": "10"
    }
)
```

Référence des options de connexion Salesforce Commerce Cloud

Les options de connexion pour Salesforce Commerce Cloud sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Salesforce Commerce Cloud.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Rest de Salesforce Commerce Cloud que vous souhaitez utiliser. Exemple : v1.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Limites

Les limites du connecteur Salesforce Commerce Cloud sont les suivantes :

- Le filtre Contains ne fonctionne pas comme prévu lors du partitionnement.
- L'entité CDN Zones ne prend pas en charge les instances sandbox et ne prend en charge que les types d'instances de développement et de production. Pour plus d'informations, consultez https://help.salesforce.com/s/ArticleView?id=cc.b2c_embedded_cdn_overview.htm.
- Dans Salesforce Commerce Cloud, il n'existe aucun point de terminaison d'API pour récupérer les métadonnées dynamiques. Par conséquent, aucune disposition ne permet de prendre en charge les champs personnalisés dans l'entité Produit et Catégorie.
- L'identifiant du site est un paramètre de requête obligatoire. Vous devez transmettre la valeur de l'identifiant du site via le paramètre de connecteur personnalisé. Pour plus d'informations, consultez [URL de base et formation des demandes](#).

- Vous pouvez appliquer des filtres sur un maximum de deux champs (à l'exception des niveaux s'ils sont présents) dans une seule demande d'API en combinant différents opérateurs, comme indiqué dans le tableau ci-dessous :

Critères de filtrage	Est pris en charge ?
Un champ avec l'opérateur CONTAINS dans une seule demande d'API.	Oui
Un champ avec l'opérateur Equals dans une seule demande d'API.	Oui
Un champ avec l'opérateur BETWEEN dans une seule demande d'API.	Oui
Deux champs ou plus avec l'opérateur CONTAINS dans une seule demande d'API.	Non
Deux champs ou plus avec l'opérateur Equals dans une seule demande d'API.	Non
Deux champs ou plus avec l'opérateur BETWEEN dans une seule demande d'API.	Non
Un champ avec Equals et un champ avec l'opérateur CONTAINS dans une seule demande d'API.	Oui
Un champ avec BETWEEN et un champ avec l'opérateur CONTAINS dans une seule demande d'API.	Oui
Un champ avec BETWEEN et un champ avec l'opérateur Equals dans une seule demande d'API.	Oui
Un champ avec Equals, un champ avec CONTAINS et un champ avec l'opérateur BETWEEN dans une seule demande d'API.	Non

Critères de filtrage	Est pris en charge ?
Un champ avec l'opérateur Equals lorsque INCREMENTAL PULL est appliqué dans une seule demande d'API.	Oui
Un champ avec l'opérateur CONTAINS lorsque INCREMENTAL PULL est appliqué dans une seule demande d'API.	Oui
Un champ avec l'opérateur BETWEEN lorsque INCREMENTAL PULL est appliqué dans une seule demande d'API.	Non
Un opérateur Equals et un opérateur CONTAINS lorsque INCREMENTAL PULL est appliqué dans une seule requête d'API.	Non

- Dans certaines entités, le type de données des champs lors de la récupération est différent de celui utilisé comme champs consultables. Par conséquent, aucune fonction de filtrage n'est prévue pour ces champs. Le tableau suivant fournit des informations détaillées sur ces champs.

N° Sr.	Nom de l'entité	Nom du champ consultable	Type de données consultable	Type de données récupérable
1	Catalogue	name	Chaîne	Struct
2	Catalogue	description	Chaîne	Struct
3	Catégorie	name	Chaîne	Struct
4	Catégorie	description	Chaîne	Struct
5	Produit (langue française non garantie)	name	Chaîne	Struct

N° Sr.	Nom de l'entité	Nom du champ consultable	Type de données consultable	Type de données récupérable
6	Produit (langue française non garantie)	recherchable	Booléen	Struct
7	Produit (langue française non garantie)	Valable à partir de	DateTime	Struct
8	Produit (langue française non garantie)	Valable pour	DateTime	Struct
9	Produit (langue française non garantie)	type	Chaîne	Struct
10	Produit (langue française non garantie)	Drapeau en ligne	Booléen	Struct
11	Promotion	name	Chaîne	Struct

Connexion à Salesforce Marketing Cloud Account Engagement

Salesforce Marketing Cloud Account Engagement est une solution d'automatisation du marketing qui aide les entreprises à créer des liens significatifs, à générer plus de pipeline et à permettre aux ventes de conclure davantage de ventes. Si vous êtes un utilisateur de Salesforce Marketing Cloud Account Engagement, vous pouvez vous connecter AWS Glue à votre compte Salesforce Marketing Cloud Account Engagement. Vous pouvez utiliser Salesforce Marketing Cloud Account Engagement comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer les données de Salesforce Marketing Cloud Account Engagement vers AWS des services ou d'autres applications prises en charge.

Rubriques

- [AWS Glue prise en charge de l'engagement des comptes Salesforce Marketing Cloud](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de l'engagement des comptes Salesforce Marketing Cloud](#)
- [Configuration des connexions d'engagement des comptes Salesforce Marketing Cloud](#)
- [Lecture à partir des entités d'engagement des comptes Salesforce Marketing Cloud](#)
- [Options de connexion à l'engagement du compte Salesforce Marketing Cloud](#)
- [Limitations et remarques relatives au connecteur d'engagement des comptes Salesforce Marketing Cloud](#)

AWS Glue prise en charge de l'engagement des comptes Salesforce Marketing Cloud

AWS Glue prend en charge l'engagement des comptes Salesforce Marketing Cloud comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Salesforce Marketing Cloud Account Engagement en mode asynchrone ou synchronisé.

Soutenu en tant que cible ?

Non.

Versions de l'API d'engagement des comptes Salesforce Marketing Cloud prises en charge

Les versions suivantes de l'API Salesforce Marketing Cloud Account Engagement sont prises en charge :

- v5

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
```

```
{
  "Effect": "Allow",
  "Action": [
    "glue:ListConnectionTypes",
    "glue:DescribeConnectionType",
    "glue:RefreshOAuth2Tokens",
    "glue:ListEntities",
    "glue:DescribeEntity"
  ],
  "Resource": "*"
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de l'engagement des comptes Salesforce Marketing Cloud

Avant de pouvoir AWS Glue transférer des données depuis Salesforce Marketing Cloud Account Engagement, vous devez répondre aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous disposez d'un compte marketing Salesforce.
- Vous disposez d'un plan d'engagement de compte sous licence pour le compte Salesforce.

- Vous avez synchronisé l'utilisateur Salesforce avec l'utilisateur Account Engagement.
- Vous avez créé une nouvelle application connectée sous App Manager pour obtenir des OAuth informations d'identification.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Salesforce Marketing Cloud Account Engagement.

Configuration des connexions d'engagement des comptes Salesforce Marketing Cloud

Le type de subvention détermine le mode AWS Glue de communication avec Salesforce Marketing Cloud Account Engagement pour demander l'accès à vos données. Votre choix influe sur les exigences que vous devez respecter avant de créer la connexion. Salesforce Marketing Cloud Account Engagement ne prend en charge que le type de subvention `AUTHORIZATION_CODE` pour la version 2.0. OAuth

- Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers un serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console.
- Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans Salesforce Marketing Cloud Account Engagement et de fournir leur propre identifiant client et leur secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Salesforce Marketing Cloud Account Engagement pour se connecter et autoriser AWS Glue l'accès à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- Pour consulter la documentation publique relative à l'engagement des comptes Salesforce Marketing Cloud sur la création d'une application connectée pour le OAuth flux de code d'autorisation, consultez [Authentification](#).

Pour configurer une connexion à un compte Salesforce Marketing Cloud Account Engagement :

1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Salesforce Marketing Cloud Account Engagement.

- b. Indiquez l'instance INSTANCE_URL d'engagement de compte Salesforce Marketing Cloud à laquelle vous souhaitez vous connecter.
- c. Indiquez l'instance PARDOT_BUSINESS_UNIT_ID d'engagement de compte Salesforce Marketing Cloud à laquelle vous souhaitez vous connecter.
- d. Sélectionnez l'URL du code d'autorisation approprié dans la liste déroulante.
- e. Sélectionnez l'URL du jeton appropriée dans le menu déroulant.
- f. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- g. Indiquez l'ID client de l'application client gérée par l'utilisateur (l'ID client de l'application connectée).
 - h. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons. Le secret sélectionné doit comporter une clé USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET dont la valeur est le secret client de l'application connectée.
 - i. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.
 3. Dans la configuration de votre AWS Glue tâche, fournissez connectionName une connexion réseau supplémentaire.

Lecture à partir des entités d'engagement des comptes Salesforce Marketing Cloud

Prérequis

Un objet d'engagement du compte Salesforce Marketing Cloud dont vous aimeriez lire un extrait.
Vous aurez besoin du nom de l'objet.

Entités prises en charge pour Sync source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Campagne	Oui	Oui	Oui	Oui	Oui
Contenu dynamique	Oui	Oui	Oui	Oui	Oui
E-mails	Oui	Oui	Oui	Oui	Oui
Modèle d'e-mail	Oui	Oui	Oui	Oui	Oui
Programme Engagement Studio	Oui	Oui	Oui	Oui	Oui
Contenu du dossier	Oui	Oui	Oui	Oui	Oui
Page de destination	Oui	Oui	Oui	Oui	Oui
Historique du cycle de vie	Oui	Oui	Oui	Oui	Oui
Étape du cycle de vie	Oui	Oui	Oui	Oui	Oui
Liste	Oui	Oui	Oui	Oui	Oui

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Adresse e-mail de la liste	Oui	Oui	Oui	Oui	Oui
Adhésion à la liste	Oui	Oui	Oui	Oui	Oui
Opportunité	Oui	Oui	Oui	Oui	Oui
Prospect	Oui	Oui	Oui	Oui	Oui
Compte Prospect	Oui	Oui	Oui	Oui	Oui
Utilisateur	Oui	Oui	Oui	Oui	Oui

Exemple :

```
salesforcepardot_read = glueContext.create_dynamic_frame.from_options(
    connection_type="SalesforcePardot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v5"
    }
)
```

Entités prises en charge pour la source asynchrone :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Campagne	Oui	Non	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Contenu dynamique	Oui	Non	Non	Oui	Non
Modèle d'e-mail	Oui	Non	Non	Oui	Non
Page de destination	Oui	Non	Non	Oui	Non
Historique du cycle de vie	Oui	Non	Non	Oui	Non
Étape du cycle de vie	Oui	Non	Non	Oui	Non
Liste	Oui	Non	Non	Oui	Non
Adresse e-mail de la liste	Oui	Non	Non	Oui	Non
Adhésion à la liste	Oui	Non	Non	Oui	Non
Opportunité	Oui	Non	Non	Oui	Non
Prospect	Oui	Non	Non	Oui	Non
Compte Prospect	Oui	Non	Non	Oui	Non
Utilisateur	Oui	Non	Non	Oui	Non

Exemple :

```
salesforcepardot_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="SalesforcePardot",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "entityName",  
        "API_VERSION": "v5",  
        "TRANSFER_MODE": "ASYNC"  
    }  
)
```

Détails de l'entité et du champ d'engagement du compte Salesforce Marketing Cloud :

Pour afficher les détails des champs pour les entités suivantes, accédez à l'[API Salesforce Marketing Cloud Account Engagement](#), choisissez Guides, faites défiler la page vers le bas jusqu'à Open Source API Wrappers, développez la version 5 Docs dans le menu et choisissez une entité.

Liste des entités :

- Campagne
- Contenu dynamique
- E-mails
- Modèle d'e-mail
- Programme Engagement Studio
- Contenu du dossier
- Page de destination
- Historique du cycle de vie
- Étape du cycle de vie
- Liste
- Adresse e-mail de la liste
- Adhésion à la liste
- Opportunité
- Prospect
- Compte Prospect
- Utilisateur

Outre les champs mentionnés ci-dessus, le mode asynchrone prend en charge des champs filtrables spécifiques pour chaque entité, comme indiqué dans le tableau ci-dessous.

Entité	Champs filtrables supplémentaires pris en charge dans Async
Campagne	<code>createdAfter</code> , <code>createdBefore</code> , <code>deleted</code> , <code>updatedAfter</code> , <code>updatedBefore</code>
Contenu dynamique	<code>createdAfter</code> , <code>createdBefore</code> , <code>deleted</code> , <code>updatedAfter</code> , <code>updatedBefore</code>
Modèle d'e-mail	<code>createdAfter</code> , <code>createdBefore</code> , <code>deleted</code> , <code>updatedAfter</code> , <code>updatedBefore</code>
Programme Engagement Studio	-
Page de destination	<code>createdAfter</code> , <code>createdBefore</code> , <code>deleted</code> , <code>updatedAfter</code> , <code>updatedBefore</code>
Historique du cycle de vie	<code>createdAfter</code> , <code>createdBefore</code>
Étape du cycle de vie	<code>createdAfter</code> , <code>createdBefore</code> , <code>deleted</code> , <code>updatedAfter</code> , <code>updatedBefore</code>
Liste	<code>createdAfter</code> , <code>createdBefore</code> , <code>deleted</code> , <code>updatedAfter</code> , <code>updatedBefore</code>
Adresse e-mail de la liste	<code>createdAfter</code> , <code>createdBefore</code> , <code>deleted</code> , <code>updatedAfter</code> , <code>updatedBefore</code>

Entité	Champs filtrables supplémentaires pris en charge dans Async
Adhésion à la liste	<code>createdAfter</code> , <code>createdBefore</code> , <code>deleted</code> , <code>updatedAfter</code> , <code>updatedBefore</code>
Opportunité	<code>createdAfter</code> , <code>createdBefore</code> , <code>deleted</code> , <code>updatedAfter</code> , <code>updatedBefore</code>
Prospect	<code>createdAfter</code> , <code>createdBefore</code> , <code>deleted</code> , <code>updatedAfter</code> , <code>updatedBefore</code>
Compte Prospect	<code>createdAfter</code> , <code>createdBefore</code> , <code>deleted</code>
Utilisateur	<code>createdAfter</code> , <code>createdBefore</code> , <code>deleted</code> , <code>updatedAfter</code> , <code>updatedBefore</code>

Pour plus d'informations sur les champs supplémentaires, consultez l'[API Salesforce Export](#)

Tenez compte des considérations suivantes concernant le connecteur :

- La valeur du `delete` champ dans les entités peut être `false` (par défaut)`true`, ou `null`.

Requêtes de partitionnement

Partitionnement basé sur des filtres :

Vous pouvez fournir les options supplémentaires de Spark

`PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, et `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.

- LOWER_BOUND: une valeur limite inférieure inclusive du champ de partition choisi.

Pour le champ Datetime, nous acceptons le format d'horodatage Spark utilisé dans SPark les requêtes SQL.

Exemples de valeurs valides :

```
"2022-01-01T01:01:01.000Z"
```

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: le nombre de partitions.
- PARTITION_BY: le type de partitionnement à effectuer. « FIELD » doit être transmis en cas de partitionnement basé sur des champs.

Exemple :

```
salesforcepardot_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="salesforcepardot",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "entityName",  
        "API_VERSION": "v5",  
        "PARTITION_FIELD": "createdAt"  
        "LOWER_BOUND": "2022-01-01T01:01:01.000Z"  
        "UPPER_BOUND": "2024-01-01T01:01:01.000Z"  
        "NUM_PARTITIONS": "10",  
        "PARTITION_BY": "FIELD"  
    }  
)
```

Options de connexion à l'engagement du compte Salesforce Marketing Cloud

Les options de connexion pour Salesforce Marketing Cloud Account Engagement sont les suivantes :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Salesforce Marketing Cloud Account Engagement.
- PARDOT_BUSINESS_UNIT_ID- (Obligatoire) Utilisé pour créer une connexion. L'ID de l'unité commerciale de l'instance Salesforce Marketing Cloud Account Engagement à laquelle vous souhaitez vous connecter.

- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API REST Salesforce Marketing Cloud Account Engagement que vous souhaitez utiliser.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(Chaîne) -
 - En mode synchronisation, valeur par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
 - En mode asynchrone, valeur par défaut : DateTime valeur actuelle (selon le fuseau horaire de l'utilisateur) : 1 an. Utilisé pour la lecture.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.
- **INSTANCE_URL**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Une URL d'instance d'engagement de compte Salesforce Marketing Cloud valide.
- **PARTITION_BY**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Type de partitionnement à effectuer. « FIELD » doit être transmis en cas de partitionnement basé sur des champs.
- **TRANSFER_MODE**(String) - (Facultatif), valeur à utiliser pour exécuter une tâche en mode ASYNC, si cette option n'est pas fournie, la tâche s'exécutera en mode SYNC.

Limitations et remarques relatives au connecteur d'engagement des comptes Salesforce Marketing Cloud

Les remarques et restrictions suivantes s'appliquent :

- Lorsqu'une limite et un partitionnement sont appliqués, la limite a priorité sur le partitionnement.
- Conformément aux documents de l'API, SalesforceMarketingCloudEngagement application d'une RateLimit sur les demandes quotidiennes et simultanées. Pour plus d'informations, consultez la section [Limites de débit](#).

- L'API d'exportation est soumise à la limite quotidienne d'appels de l'API Account Engagement et à la limite d'appels simultanés de l'API Account Engagement pour votre compte.
- À l'instar d'une file d'attente, les appels d'API Export/Async sont exécutés de manière séquentielle pour chaque compte. Les anciennes exportations sont traitées avant les nouvelles exportations.
- La partition n'est pas prise en charge en mode asynchrone.
- Le nombre de champs sélectionnés spécifiés dans les appels d'API Export/Async ne peut pas dépasser 150.
- L'entité Prospect prend en charge plus de 150 champs, mais seuls 150 champs peuvent être sélectionnés à la fois. Si `Select All` cette option est sélectionnée, certains champs seront exclus. Pour récupérer les données de ces champs exclus, vous devez les inclure dans l'`Selected Fields` option.

Voici la liste des champs exclus dans `SELECT_ALL -updatedBy.firstName, updatedBy.lastName, updatedBy.jobTitle, updatedBy.roleName, updatedBy.salesforceId, updatedBy.updatedAt, updatedBy.isDeleted, updatedBy.createdById, updatedBy.updatedBy, updatedBy.tagReplacementLanguage`

- Les champs de collection ne peuvent pas être exportés pour Async. Par exemple, dans List Email, les `replyToOptions` champs `senderOptions` et ne sont pas pris en charge.
- Pour toutes les entités, le filtre est obligatoire. Si aucun filtre n'est fourni, le prédicat de filtre par défaut est défini `Created After` sur le champ avec une valeur de la date-heure actuelle (ajustée à votre fuseau horaire) moins un an.
- Conformément aux limites d'engagement des comptes Salesforce Marketing Cloud, en mode asynchrone, la plage maximale pour récupérer les données est d'un an. Si une requête est fournie depuis plus d'un an, la tâche générera une erreur.
- Il existe actuellement un bogue dans Salesforce Pardot. Lorsque la tâche inclut un seul champ qui ne contient aucune donnée, la valeur du champ ne renvoie pas le résultat correct et le nom du champ est renvoyé plusieurs fois. L'équipe Salesforce Pardot est consciente du problème et travaille activement à sa résolution.

Connexion à SAP HANA dans AWS Glue Studio

AWS Glue fournit un support intégré pour SAP HANA. AWS Glue Studio fournit une interface visuelle pour se connecter à SAP HANA, créer des tâches d'intégration de données et les exécuter sur AWS Glue Studio environnement d'exécution Spark sans serveur.

AWS Glue Studio crée une connexion unifiée pour SAP HANA. Pour de plus amples informations, veuillez consulter [Considérations](#).

Rubriques

- [Création d'une connexion SAP HANA](#)
- [Création d'un nœud source SAP HANA](#)
- [Création d'un nœud cible SAP HANA](#)
- [Options avancées](#)

Création d'une connexion SAP HANA

Pour vous connecter à SAP HANA depuis AWS Glue, vous devez créer et stocker vos informations d'identification SAP HANA dans un AWS Secrets Manager secret, puis associer ce secret à une connexion SAP AWS Glue HANA. Vous devrez configurer la connectivité réseau entre votre service SAP HANA et AWS Glue.

Prérequis :

- Si votre service SAP HANA se trouve dans un Amazon VPC, configurez Amazon VPC pour permettre à AWS Glue votre tâche de communiquer avec le service SAP HANA sans que le trafic ne transite par l'Internet public.

Dans Amazon VPC, identifiez ou créez un VPC, un sous-réseau et un groupe de sécurité qui AWS Glue seront utilisés lors de l'exécution de la tâche. En outre, vous devez vous assurer qu'Amazon VPC est configuré pour autoriser le trafic réseau entre votre point de terminaison SAP HANA et cet emplacement. Votre tâche devra établir une connexion TCP avec votre port JDBC SAP HANA. Pour plus d'informations sur les ports SAP HANA, consultez [la documentation SAP HANA](#). Selon la configuration de votre réseau, cela peut nécessiter des modifications des règles du groupe de sécurité, du réseau ACLs, des passerelles NAT et des connexions d'appairage.

Pour configurer une connexion à SAP HANA :

1. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification SAP HANA. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret `secretName` pour l'étape suivante.

- Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé `user` contenant la valeur. *saphanaUsername*
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé `password` contenant la valeur. *saphanaPassword*
2. Dans la AWS Glue console, créez une connexion en suivant les étapes décrites dans [the section called “Ajouter une AWS Glue connexion”](#). Après avoir créé la connexion, conservez le nom de la connexion pour une utilisation future dans AWS Glue. *connectionName*
- Lorsque vous sélectionnez un type de connexion, sélectionnez SAP HANA.
 - Lorsque vous fournissez l'URL SAP HANA, indiquez l'URL de votre instance.

SAP HANA JDBC URLs sont sous la forme

`jdbc:sap://saphanaHostname:saphanaPort/?databaseName=saphanaDBname,Paramete`

AWS Glue nécessite les paramètres d'URL JDBC suivants :

- `databaseName` – une base de données par défaut dans SAP HANA à laquelle se connecter.
- Lorsque vous sélectionnez un AWS secret, fournissez *secretName*.

Après avoir créé une connexion AWS Glue SAP HANA, vous devez effectuer les étapes suivantes avant d'exécuter votre AWS Glue tâche :

- Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire *secretName*.

Création d'un nœud source SAP HANA

Prérequis

- Une connexion AWS Glue SAP HANA, configurée avec un AWS Secrets Manager secret, comme décrit dans la section précédente, [the section called “Création d'une connexion SAP HANA”](#).
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.
- Une table SAP HANA que vous souhaitez lire ou interroger *targetQuery*. *tableName*

Une table peut être spécifiée avec un nom de table SAP HANA et un nom de schéma, sous forme de *schemaName*. *tableName*. Le nom du schéma et le séparateur « . » ne sont pas obligatoires si

la table se trouve dans le schéma par défaut, « public ». Appelle ça *tableIdentifier*. Notez que la base de données est fournie sous forme de paramètre d'URL JDBC dans `connectionName`.

Ajout d'une source de données SAP HANA

Pour ajouter un nœud Source de données – SAP HANA :

1. Choisissez la connexion pour votre source de données SAP HANA. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Créer une connexion SAP HANA. Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion SAP HANA”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Choisissez une option Source SAP HANA :
 - Choisissez une seule table : accéder à toutes les données à partir d'une seule table.
 - Saisir une requête personnalisée : accéder à un jeu de données à partir de plusieurs tables en fonction de votre requête personnalisée.
3. Si vous avez choisi une seule table, entrez *tableName*.

Si vous avez choisi Saisir une requête personnalisée, saisissez une requête SQL SELECT.

4. Dans les Propriétés SAP HANA personnalisées, saisissez les paramètres et les valeurs nécessaires.

Création d'un nœud cible SAP HANA

Prérequis

- Une connexion AWS Glue SAP HANA, configurée avec un AWS Secrets Manager secret, comme décrit dans la section précédente, [the section called “Création d'une connexion SAP HANA”](#).
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.
- Une table SAP HANA dans laquelle vous souhaitez écrire, *tableName*.

Une table peut être spécifiée avec un nom de table SAP HANA et un nom de schéma, sous forme de *schemaName.tableName*. Le nom du schéma et le séparateur « . » ne sont pas obligatoires si

la table se trouve dans le schéma par défaut, « public ». Appelle ça *tableIdentifier*. Notez que la base de données est fournie sous forme de paramètre d'URL JDBC dans `connectionName`.

Ajout d'une cible de données SAP HANA

Pour ajouter un nœud Cible de données – SAP HANA :

1. Choisissez la connexion pour votre source de données SAP HANA. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Créer une connexion SAP HANA. Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion SAP HANA”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Configurez le nom de la table en fournissant *tableName*.
3. Dans les Propriétés Teradata personnalisées, saisissez les paramètres et les valeurs nécessaires.

Options avancées

Vous pouvez fournir des options avancées lors de la création d'un nœud SAP HANA. Ces options sont les mêmes que celles disponibles lors de la programmation AWS Glue de scripts Spark.

Consultez [the section called “Connexions SAP HANA”](#).

Connexion à SAP OData

SAP OData est un protocole Web standard utilisé pour interroger et mettre à jour les données présentes dans SAP à l'aide de l'ABAP (Advanced Business Application Programming), en appliquant et en s'appuyant sur des technologies Web telles que le HTTP pour fournir un accès aux informations provenant de diverses applications, plateformes et appareils externes. Avec le produit, vous pouvez accéder à tout ce dont vous avez besoin pour vous intégrer parfaitement à votre système, à votre application ou à vos données SAP.

Rubriques

- [AWS Glue support pour SAP OData](#)
- [Créez des connexions](#)

- [Création d'un OData job SAP](#)
- [Utilisation du script de gestion OData d'état SAP](#)
- [Partitionnement pour les entités non ODP](#)
- [Options de OData connexion SAP](#)
- [Détails de OData l'entité et du champ SAP](#)

AWS Glue support pour SAP OData

AWS Glue prend en charge SAP OData comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de SAP OData.

Versions d' OData API SAP prises en charge

Les versions d' OData API SAP suivantes sont prises en charge :

- 2.0

Sources prises en charge

Les sources suivantes sont prises en charge :

- Sources ODP (approvisionnement des données opérationnelles) :
 - Extracteurs BW (1) DataSources
 - Vues CDS
 - SLT
- Sources non ODP, par exemple :
 - Services CDS View
 - Services basés sur le RFC
 - Services ABAP personnalisés

Composants SAP pris en charge

Les exigences minimales suivantes sont les suivantes :

- Vous devez activer le service de catalogue pour la découverte de services.
 - Configurez les sources de données ODP (Operational Data Provisioning) à extraire dans la passerelle SAP de votre système SAP.
 - OData V2.0 : Activez le ou les services de catalogue OData V2.0 dans votre passerelle SAP via une transaction. /IWFND/MAINT_SERVICE
 - Activez les services OData V2.0 dans votre passerelle SAP via une transaction. /IWFND/MAINT_SERVICE
 - Votre OData service SAP doit prendre en charge les options de pagination/de requête côté client telles que `et. $top $skip` Il doit également prendre en charge l'option de requête système `$count`.
 - Vous devez fournir l'autorisation requise pour que l'utilisateur puisse découvrir les services et extraire les données à l'aide des OData services SAP. Reportez-vous à la documentation de sécurité fournie par SAP.
- Si vous souhaitez utiliser la OAuth version 2.0 comme mécanisme d'autorisation, vous devez activer la OAuth version 2.0 pour le OData service et enregistrer le OAuth client conformément à la documentation SAP.
- Pour générer un OData service basé sur des sources de données ODP, SAP Gateway Foundation doit être installé localement dans votre stack ERP/BW ou dans une configuration de hub.
 - Pour vos applications ERP/BW, la pile SAP NetWeaver AS ABAP doit être de 7,50 SP02 ou plus.
 - Pour le système de hub (SAP Gateway), le SAP NetWeaver AS ABAP du système de hub doit être 7.50 SP01 ou supérieur pour la configuration du hub distant.
- Pour les sources non ODP, la version de votre NetWeaver stack SAP doit être 7.40 SP02 ou supérieure.

Méthodes d'authentification prises en charge

Les méthodes d'authentification suivantes sont prises en charge :

- Authentification de base
- OAuth 2,0

Prérequis

Avant de lancer une AWS Glue tâche d'extraction de données depuis SAP à OData l'aide de la OData connexion SAP, remplissez les conditions préalables suivantes :

- Le OData service SAP correspondant doit être activé dans le système SAP, afin de garantir que la source de données est disponible pour la consommation. Si le OData service n'est pas activé, la tâche Glue ne pourra pas accéder aux données de SAP ni en extraire.
- Les mécanismes d'authentification appropriés tels que l'authentification de base (personnalisée) ou OAuth 2.0 doivent être configurés dans SAP pour garantir que la AWS Glue tâche puisse établir avec succès une connexion avec le OData service SAP.
- Configurez les politiques IAM pour accorder à la AWS Glue tâche les autorisations appropriées pour accéder à SAP, à Secrets Manager et aux autres AWS ressources impliquées dans le processus.
- Si le système SAP est hébergé sur un réseau privé, la connectivité VPC doit être configurée pour garantir que la AWS Glue tâche puisse communiquer en toute sécurité avec SAP sans exposer de données sensibles sur Internet public.

AWS Secrets Manager peut être utilisé pour stocker en toute sécurité des informations sensibles telles que les informations d'identification SAP, que la AWS Glue tâche peut récupérer dynamiquement lors de l'exécution. Cette approche élimine le besoin de coder en dur les informations d'identification, ce qui améliore la sécurité et la flexibilité.

Les prérequis suivants fournissent des step-by-step conseils sur la façon de configurer chaque composant pour une intégration fluide entre SAP AWS Glue et SAP OData.

Rubriques

- [OData Activation de SAP](#)
- [Politiques IAM](#)
- [Connectivité/Connexion VPC](#)
- [Authentification SAP](#)
- [AWS Secrets Manager pour stocker votre secret d'authentification](#)

OData Activation de SAP

Procédez comme suit pour la OData connexion SAP :

Sources d'ODP

Avant de pouvoir transférer des données depuis un fournisseur ODP, vous devez satisfaire aux exigences suivantes :

- Vous disposez d'une instance SAP NetWeaver AS ABAP.
- Votre NetWeaver instance SAP contient un fournisseur ODP à partir duquel vous souhaitez transférer des données. Les fournisseurs ODP incluent :
 - SAP DataSources (code de transaction RSO2)
 - Vues ABAP CDS des services de données SAP Core
 - Systèmes SAP BW ou SAP BW/4HANA (, Object) InfoObject DataStore
 - Réplication en temps réel de tables et de vues de base de données depuis le système source SAP via SAP Landscape Replication Server (SAP SLT)
 - Vues d'informations SAP HANA dans des sources basées sur SAP ABAP
- Votre NetWeaver instance SAP possède le composant SAP Gateway Foundation.
- Vous avez créé un OData service qui extrait les données de votre fournisseur ODP. Pour créer le OData service, vous utilisez le SAP Gateway Service Builder. Pour accéder à vos données ODP, Amazon AppFlow appelle ce service à l'aide de l' OData API. Pour plus d'informations, consultez la section [Génération d'un service d'extraction de données ODP OData](#) dans la documentation SAP BW/4HANA.
- Pour générer un OData service basé sur des sources de données ODP, SAP Gateway Foundation doit être installé localement dans votre stack ERP/BW ou dans une configuration de hub.
 - Pour vos applications ERP/BW, la pile SAP NetWeaver AS ABAP doit être de 7,50 SP02 ou plus.
 - Pour le système de hub (SAP Gateway), le SAP NetWeaver AS ABAP du système de hub doit être 7.50 SP01 ou supérieur pour la configuration du hub distant.

Sources autres que le PDO

- Votre version de SAP NetWeaver Stack doit être 7.40 SP02 ou supérieure.
- Vous devez activer le service de catalogue pour la découverte de services.
 - OData V2.0 : Le ou les services de catalogue OData V2.0 peuvent être activés dans votre SAP Gateway via une transaction /IWFND/MAINT_SERVICE
- Votre OData service SAP doit prendre en charge les options de pagination/de requête côté client telles que `et. $top $skip` Il doit également prendre en charge l'option de requête système `$count`.
- Pour la OAuth version 2.0, vous devez activer la OAuth version 2.0 pour le OData service, enregistrer le OAuth client conformément à la documentation SAP et définir l'URL de redirection autorisée comme suit :

- `https://<region>.console.aws.amazon.com/gluestudio/oauth`, en `<region>` remplaçant par la région dans laquelle AWS Glue s'exécute, par exemple : `us-east-1`.
- Vous devez activer la configuration sécurisée pour vous connecter via HTTPS.
- Vous devez fournir l'autorisation requise à l'utilisateur dans SAP pour découvrir les services et extraire les données à l'aide des OData services SAP. Reportez-vous à la documentation de sécurité fournie par SAP.

Politiques IAM

Politiques contenant les opérations d'API pour la création et l'utilisation de connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    },
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue"
      ],
      "Resource": "*"
    }
  ]
}
```

Le rôle doit accorder l'accès à toutes les ressources utilisées par la tâche, par exemple Amazon S3. Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes.

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.
- [SecretsManagerReadWrite](#)— Fournit un accès en lecture/écriture à AWS Secrets Manager via la console de AWS gestion. Remarque : cela exclut les actions IAM, alors combinez-les `IAMFullAccess` si une configuration de rotation est requise.

Politiques/autorisations IAM nécessaires pour configurer le VPC

Les autorisations IAM suivantes sont requises lors de l'utilisation d'une connexion VPC pour AWS Glue créer une connexion. Pour plus de détails, reportez-vous à la section [Création d'une politique IAM pour AWS Glue](#).

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "ec2:CreateNetworkInterface",
        "ec2:DeleteNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
      ],
      "Resource": [
        "*"
      ]
    }
  ]
}
```

```
]
}
```

Connectivité/Connexion VPC

Étapes de connexion VPC :

1. Utilisez la connexion VPC existante ou créez une nouvelle connexion en suivant la documentation Amazon [VPC](#).
2. Assurez-vous que vous disposez d'une passerelle NAT qui achemine le trafic vers Internet.
3. Choisissez le point de terminaison VPC comme Amazon S3 Gateway pour créer une connexion.
4. Activez la résolution DNS et le nom d'hôte DNS pour utiliser les services DNS AWS fournis.
5. Accédez au VPC créé et ajoutez les points de terminaison nécessaires pour différents services tels que STS AWS Glue, Secret Managers.
 - a. Choisissez Créer un point de terminaison.
 - b. Pour Catégorie de service, sélectionnez AWS Services.
 - c. Dans Nom du service, choisissez le service auquel vous vous connectez.
 - d. Choisissez VPC et activez le nom DNS.
 - e. Points de terminaison VCP requis pour la connexion VPC :
 - i. [STS](#)
 - ii. [AWS Glue](#)
 - iii. [Secrets Manager](#)

Configuration du groupe de sécurité

Le groupe de sécurité doit autoriser le trafic vers son port d'écoute depuis le AWS Glue VPC AWS Glue pour pouvoir s'y connecter. Il est recommandé de limiter autant que possible la plage d'adresses IP sources.

AWS Glue nécessite un groupe de sécurité spécial qui autorise tout le trafic entrant à partir de lui-même. Vous pouvez créer une règle d'autoréférencement qui autorise tout le trafic provenant du groupe de sécurité. Vous pouvez modifier un groupe de sécurité existant et le spécifier comme source.

Ouvrez la communication depuis les ports HTTPS du point de terminaison de l'URL (instance NLB ou SAP).

Options de connectivité

- Connexion HTTPS avec NLB interne et externe, certificat SSL de l'autorité de certification (CA), certificat SSL non auto-signé
- Connexion HTTPS avec certificat SSL de l'instance SAP délivré par l'autorité de certification (CA), et non un certificat SSL auto-signé

Authentification SAP

Le connecteur SAP prend en charge les méthodes d'authentification CUSTOM (authentification SAP BASIC) et OAUTH.

Authentification personnalisée

AWS Glue prend en charge l'authentification personnalisée (authentification de base) comme méthode d'établissement de connexions à vos systèmes SAP, permettant l'utilisation d'un nom d'utilisateur et d'un mot de passe pour un accès sécurisé. Ce type d'authentification fonctionne bien pour les scénarios d'automatisation car il permet d'utiliser le nom d'utilisateur et le mot de passe dès le départ avec les autorisations d'un utilisateur particulier dans l' OData instance SAP. AWS Glue est capable d'utiliser le nom d'utilisateur et le mot de passe pour authentifier SAP OData APIs. Dans AWS Glue, l'autorisation de base est implémentée en tant qu'autorisation personnalisée.

Pour consulter la OData documentation SAP publique sur le flux d'authentification de base, consultez la section [Authentification de base HTTP](#).

OAuth 2.0 Authentification

AWS Glue prend également en charge la OAuth version 2.0 en tant que mécanisme d'authentification sécurisé pour établir des connexions à vos systèmes SAP. Cela permet une intégration fluide tout en garantissant la conformité aux normes d'authentification modernes et en renforçant la sécurité de l'accès aux données.

AUTHORIZATION_CODE Type de subvention

Le type de subvention détermine le AWS Glue mode de communication avec SAP OData pour demander l'accès à vos données. SAP ne OData prend en charge que le type de AUTHORIZATION_CODE subvention. Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console.

Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans SAP OData et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers SAP pour OData se connecter et autoriser AWS Glue l'accès à leurs ressources.

Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.

Pour consulter OData la documentation SAP publique sur la création d'une application connectée pour le OAuth flux de code d'autorisation, voir [Authentication Using OAuth 2.0](#).

AWS Secrets Manager pour stocker votre secret d'authentification

Vous devrez stocker les secrets de OData connexion SAP dans AWS Secrets Manager, configurer les autorisations nécessaires pour les récupérer, comme indiqué dans la [Politiques IAM](#) section, et les utiliser lors de la création d'une connexion.

Utilisez la console AWS de gestion de AWS Secrets Manager pour créer un secret pour votre source SAP. Pour plus d'informations, consultez la section [Créer un secret du Gestionnaire de AWS Secrets](#). Les informations AWS contenues dans Secrets Manager doivent inclure les éléments du code suivant.

Secret d'authentification personnalisé

Vous devrez saisir le nom d'utilisateur de votre système SAP à la place de <your SAP username> et son mot de passe à la place de <your SAP username password> True ou False. Dans ce contexte, le paramètre `true` désactive `basicAuthDisableSSO` l'authentification unique (SSO) pour les demandes d'authentification de base, en exigeant des informations d'identification utilisateur explicites pour chaque demande. Inversement, le paramétrer sur `false` autorise l'utilisation des sessions SSO existantes si elles sont disponibles.

```
{
  "basicAuthUsername": "<your SAP username>",
  "basicAuthPassword": "<your SAP username password>",
  "basicAuthDisableSSO": "<True/False>",
  "customAuthenticationType": "CustomBasicAuth"
}
```

OAuth 2.0 Secret

Si vous utilisez la OAuth version 2.0 comme mécanisme d'authentification, le secret du Gestionnaire de AWS Secrets doit avoir l'application ClientId cliente gérée par l'utilisateur au format suivant. Vous devrez saisir le secret de votre client SAP à la place de <your client secret>.

```
{"USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET": "<your client secret>"
}
```

Créez des connexions

Pour configurer une OData connexion SAP :

1. Connectez-vous à la console AWS de gestion et [AWS Glue ouvrez-la](#). Dans le AWS Glue Studio, créez une connexion en suivant les étapes ci-dessous :
 - a. Cliquez sur Connexions de données dans le panneau de gauche.
 - b. Cliquez sur Créer une connexion.
 - c. Sélectionnez SAP OData dans Choisir une source de données
 - d. Fournissez l'URL de l'hôte de l'application de l' OData instance SAP à laquelle vous souhaitez vous connecter. L'URL de l'hôte de l'application doit être accessible via Internet public pour une connexion non VPC.
 - e. Indiquez le chemin du service d'application de l' OData instance SAP à laquelle vous souhaitez vous connecter. Il s'agit du même chemin que le chemin du service de catalogue. Par exemple : /sap/opu/odata/iwfnd/catalogservice;v=2. AWS Glue n'accepte pas le chemin d'un objet spécifique.
 - f. Indiquez le numéro de client de l' OData instance SAP à laquelle vous souhaitez vous connecter. Les valeurs acceptables sont [001-999]. Exemple : 010
 - g. Indiquez le numéro de port de l' OData instance SAP à laquelle vous souhaitez vous connecter. Exemple : 443
 - h. Indiquez la langue d'ouverture de session de l' OData instance SAP à laquelle vous souhaitez vous connecter. Exemple : EN
 - i. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et qui dispose des autorisations décrites dans la [Politiques IAM](#) section.
 - j. Sélectionnez le type d'authentification que vous souhaitez utiliser pour cette connexion dans AWS Glue la liste déroulante : OAUTH2 ou PERSONNALISÉ

- i. PERSONNALISÉ - Sélectionnez le secret que vous avez créé comme indiqué dans la [AWS Secrets Manager pour stocker votre secret d'authentification](#) section.
 - ii. OAUTH 2.0 - entrez les entrées suivantes uniquement dans le cas de OAuth 2.0 :
 - A. Sous Application client gérée par l'utilisateur ClientId, entrez votre identifiant client.
 - B. USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET(votre secret client) dans le Gestionnaire de AWS Secrets que vous avez créé dans la [AWS Secrets Manager pour stocker votre secret d'authentification](#) section.
 - C. Sous URL du code d'autorisation, entrez l'URL de votre code d'autorisation.
 - D. Sous URL des jetons d'autorisation, entrez l'URL de votre jeton d'autorisation.
 - E. Sous OAuth Étendue, entrez vos OAuth portées en les séparant par un espace. Exemple :
/IWFND/SG_MED_CATALOG_0002 ZAPI_SALES_ORDER_SRV_0001
 - k. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau. Pour en savoir plus, consultez [Connectivité/Connexion VPC](#).
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName. Pour plus de détails, consultez [Politiques IAM](#).
 3. Choisissez Tester la connexion et testez votre connexion. Si le test de connexion réussit, cliquez sur Suivant, entrez le nom de votre connexion et enregistrez votre connexion. La fonctionnalité de test de connexion n'est pas disponible si vous avez sélectionné les options réseau (VPC).

Création d'un OData job SAP

Reportez-vous à la section [Création de tâches ETL visuelles avec AWS Glue Studio](#)

Sources de provisionnement des données opérationnelles (ODP)

Le provisionnement des données opérationnelles (ODP) fournit une infrastructure technique que vous pouvez utiliser pour prendre en charge l'extraction et la réplication des données pour diverses applications cibles et prend en charge les mécanismes delta dans ces scénarios. Dans le cas d'une procédure delta, les données d'une source (fournisseur ODP) sont automatiquement écrites dans une file delta (Operational Delta Queue — ODQ) à l'aide d'un processus de mise à jour ou transmises à la file delta à l'aide d'une interface d'extraction. Un fournisseur ODP peut être un DataSource (extracteurs), des vues ABAP Core Data Services (vues ABAP CDS), SAP BW ou SAP BW/4HANA, un serveur SAP Landscape Transformation Replication (SLT) et des vues d'informations SAP HANA (vues de calcul). Les applications cibles (appelées « abonnés » ODQ ou plus généralement « consommateurs ODP ») récupèrent les données de la file d'attente delta et continuent à les traiter.

Chargement complet

Dans le contexte des entités SAP OData et ODP, un chargement complet fait référence au processus d'extraction de toutes les données disponibles d'une entité ODP en une seule opération. Cette opération extrait l'ensemble de données complet du système source, garantissant ainsi que le système cible dispose d'une up-to-date copie complète des données de l'entité. Les chargements complets sont généralement utilisés pour les sources qui ne prennent pas en charge les charges incrémentielles ou lorsqu'une actualisation du système cible est requise.

Exemple

Vous pouvez définir explicitement l'ENABLE_CDCindicateur sur false lors de la création du DynamicFrame. Remarque : la valeur ENABLE_CDC est fausse par défaut. Si vous ne souhaitez pas initialiser la file d'attente delta, vous n'avez pas besoin d'envoyer cet indicateur ou de le définir sur true. Le fait de ne pas définir cet indicateur sur true entraînera une extraction à pleine charge.

```
sapodata_df = glueContext.create_dynamic_frame.from_options(  
    connection_type="SAPOData",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "entityName",  
        "ENABLE_CDC": "false"  
    }, transformation_ctx=key)
```

Charge incrémentielle

Une charge incrémentielle dans le contexte des entités ODP (Operational Data Provisioning) implique d'extraire uniquement les données nouvelles ou modifiées (deltas) du système source depuis la dernière extraction des données, évitant ainsi de prétraiter les enregistrements déjà traités. Cette approche améliore considérablement l'efficacité, réduit les volumes de transfert de données, améliore les performances, garantit une synchronisation efficace entre les systèmes et minimise le temps de traitement, en particulier pour les grands ensembles de données qui changent fréquemment.

Transferts incrémentiels basés sur des jetons Delta

Pour activer le transfert incrémental à l'aide de la capture des données de modification (CDC) pour les entités compatibles ODP qui le prennent en charge, procédez comme suit :

1. Créez la tâche de transfert incrémental en mode script.

2. Lorsque vous créez le DataFrame or Glue DynamicFrame, vous devez passer l'option "ENABLE_CDC": "True". Cette option garantit que vous recevrez un jeton Delta de la part de SAP, qui pourra être utilisé pour récupérer ultérieurement les données modifiées.

Le jeton delta sera présent dans la dernière ligne de la trame de données, dans la colonne DELTA_TOKEN. Ce jeton peut être utilisé comme option de connecteur lors des appels suivants pour récupérer de manière incrémentielle le prochain ensemble de données.

Exemple

- Nous avons défini le ENABLE_CDC drapeau sur true, lors de la création du DynamicFrame. Remarque : ENABLE_CDC false par défaut, si vous ne souhaitez pas initialiser la file d'attente delta, vous n'avez pas besoin d'envoyer cet indicateur ou de le définir sur true. Le fait de ne pas définir cet indicateur sur true entraînera une extraction à pleine charge.

```
sapodata_df = glueContext.create_dynamic_frame.from_options(
    connection_type="SAP0Data",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "ENABLE_CDC": "true"
    }, transformation_ctx=key)

# Extract the delta token from the last row of the DELTA_TOKEN column
delta_token_1 = your_logic_to_extract_delta_token(sapodata_df) # e.g.,
D20241029164449_000370000
```

- Le jeton delta extrait peut être transmis en option pour récupérer de nouveaux événements.

```
sapodata_df_2 = glueContext.create_dynamic_frame.from_options(
    connection_type="SAP0Data",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        // passing the delta token retrieved in the last run
        "DELTA_TOKEN": delta_token_1
    }, transformation_ctx=key)

# Extract the new delta token for the next run
delta_token_2 = your_logic_to_extract_delta_token(sapodata_df_2)
```

Notez que le dernier enregistrement, dans lequel le DELTA_TOKEN est présent, n'est pas un enregistrement transactionnel provenant de la source et n'est là que dans le but de transmettre la valeur du jeton delta.

Outre les DELTA_TOKEN champs suivants sont renvoyés dans chaque ligne de la trame de données.

- **GLUE_FETCH_SQ** : Il s'agit d'un champ de séquence, généré à partir de l'horodatage EPOCH dans l'ordre dans lequel l'enregistrement a été reçu, et qui est unique pour chaque enregistrement. Cela peut être utilisé si vous avez besoin de connaître ou d'établir l'ordre des modifications dans le système source. Ce champ ne sera présent que pour les entités compatibles ODP.
- **DML_STATUS** : Cela s'affichera UPDATED pour tous les enregistrements récemment insérés et mis à jour à partir de la source, ainsi que DELETED pour les enregistrements supprimés de la source.

Pour plus de détails sur la façon de gérer l'état et de réutiliser le jeton delta pour récupérer les enregistrements modifiés à l'aide d'un exemple, reportez-vous à la [Utilisation du script de gestion OData d'état SAP](#) section.

Invalidation du jeton Delta

Un jeton delta est associé à la collection de services et à un utilisateur. Si un nouveau pull with initial "ENABLE_CDC" : "true" est lancé pour la même collection de services et pour le même utilisateur, tous les jetons delta émis à la suite d'une initialisation précédente seront invalidés par le service SAP OData . L'appel du connecteur avec un jeton delta expiré entraînera une exception :

```
Could not open data access via extraction API RODPS_REPL_ODP_OPEN
```

OData Services (sources autres que le PDO)

Chargement complet

Pour les systèmes non ODP (Operational Data Provisioning), un chargement complet consiste à extraire l'ensemble de données du système source et à le charger dans le système cible. Étant donné que les systèmes non ODP ne prennent pas en charge par nature les mécanismes avancés d'extraction de données tels que les deltas, le processus est simple mais peut nécessiter beaucoup de ressources en fonction de la taille des données.

Charge incrémentielle

Pour les systèmes ou les entités qui ne prennent pas en charge l'ODP (Operational Data Provisioning), le transfert de données incrémentiel peut être géré manuellement en mettant en œuvre un mécanisme basé sur l'horodatage pour suivre et extraire les modifications.

Transferts incrémentiels basés sur l'horodatage

Pour les entités non compatibles ODP (ou pour les entités compatibles ODP qui n'utilisent pas l'indicateur `ENABLE_CDC`), nous pouvons utiliser une `filteringExpression` option du connecteur pour indiquer l'`datetime`intervalle pendant lequel nous voulons récupérer les données. Cette méthode repose sur un champ d'horodatage dans vos données qui représente la date à laquelle chaque enregistrement a été créé/modifié pour la dernière fois.

Exemple

Récupération des enregistrements modifiés après 2024-01-01T 00:00:00.000

```
sapodata_df = glueContext.create_dynamic_frame.from_options(  
    connection_type="SAP0Data",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "entityName",  
        "filteringExpression": "LastChangeDateTime >= 2024-01-01T00:00:00.000"  
    }, transformation_ctx=key)
```

Remarque : Dans cet exemple, `LastChangeDateTime` il s'agit du champ qui représente la date de dernière modification de chaque enregistrement. Le nom du champ réel peut varier en fonction de votre OData entité SAP spécifique.

Pour obtenir un nouveau sous-ensemble de données lors des exécutions suivantes, vous devez le mettre à jour `filteringExpression` avec un nouvel horodatage. Il s'agit généralement de la valeur d'horodatage maximale des données précédemment récupérées.

Exemple

```
max_timestamp = get_max_timestamp(sapodata_df) # Function to get the max timestamp  
from the previous run  
next_filtering_expression = f"LastChangeDateTime > {max_timestamp}"
```

```
# Use this next_filtering_expression in your next run
```

Dans la section suivante, nous proposerons une approche automatisée pour gérer ces transferts incrémentiels basés sur l'horodatage, éliminant ainsi le besoin de mettre à jour manuellement l'expression de filtrage entre les exécutions.

Utilisation du script de gestion OData d'état SAP

Pour utiliser le script de gestion OData d'état SAP dans le cadre de votre AWS Glue travail, procédez comme suit :

- Téléchargez le script de gestion de l'état : `s3://aws-blogs-artifacts-public/artifacts/BDB-4789/sap_odata_state_management.zip` depuis le compartiment public Amazon S3.
- Téléchargez le script dans un compartiment Amazon S3 auquel votre AWS Glue travail est autorisé à accéder.
- Référez le script dans votre AWS Glue tâche : lors de la création ou de la mise à jour de votre AWS Glue tâche, transmettez l'option `--extra-py-files` faisant référence au chemin du script dans votre compartiment Amazon S3. Par exemple : `--extra-py-files s3://your-bucket/path/to/sap_odata_state_management.py`
- Importez et utilisez la bibliothèque de gestion des états dans vos scripts de AWS Glue travail.

Exemple de transfert incrémental basé sur un jeton Delta

Voici un exemple d'utilisation du script de gestion d'état pour les transferts incrémentiels basés sur des jetons delta :

```
from sap_odata_state_management import StateManagerFactory, StateManagerType, StateType

# Initialize the state manager
state_manager = StateManagerFactory.create_manager(
    manager_type=StateManagerType.JOB_TAG,
    state_type=StateType.DELTA_TOKEN,
    options={
        "job_name": args['JOB_NAME'],
        "logger": logger
    }
)

# Get connector options (including delta token if available)
```

```

key = "SAP0DataNode"
connector_options = state_manager.get_connector_options(key)

# Use the connector options in your Glue job
df = glueContext.create_dynamic_frame.from_options(
    connection_type="SAP0Data",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "ENABLE_CDC": "true",
        **connector_options
    }
)

# Process your data here...

# Update the state after processing
state_manager.update_state(key, sapodata_df.toDF())

```

Exemple de transfert incrémental basé sur l'horodatage

Voici un exemple d'utilisation du script de gestion d'état pour les transferts incrémentiels basés sur des jetons delta :

```

from sap_odata_state_management import StateManagerFactory, StateManagerType, StateType

# Initialize the state manager
state_manager = StateManagerFactory.create_manager(
    manager_type=StateManagerType.JOB_TAG,
    state_type=StateType.DELTA_TOKEN,
    options={
        "job_name": args['JOB_NAME'],
        "logger": logger
    }
)

# Get connector options (including delta token if available)
key = "SAP0DataNode"
connector_options = state_manager.get_connector_options(key)

# Use the connector options in your Glue job
df = glueContext.create_dynamic_frame.from_options(
    connection_type="SAP0Data",

```

```
connection_options={
    "connectionName": "connectionName",
    "ENTITY_NAME": "entityName",
    "ENABLE_CDC": "true",
    **connector_options
}
)

# Process your data here...

# Update the state after processing
state_manager.update_state(key, sapodata_df.toDF())
```

Dans les deux exemples, le script de gestion d'état gère les complexités liées au stockage de l'état (jeton delta ou horodatage) entre les exécutions de tâches. Il récupère automatiquement le dernier état connu lors de l'obtention des options du connecteur et met à jour l'état après le traitement, garantissant ainsi que chaque tâche exécutée ne traite que les données nouvelles ou modifiées.

Partitionnement pour les entités non ODP

Dans Apache Spark, le partitionnement fait référence à la manière dont les données sont divisées et distribuées entre les nœuds de travail d'un cluster pour un traitement parallèle. Chaque partition est un bloc logique de données qui peut être traité indépendamment par une tâche. Le partitionnement est un concept fondamental de Spark qui a un impact direct sur les performances, l'évolutivité et l'utilisation des ressources. AWS Glue les jobs utilisent le mécanisme de partitionnement de Spark pour diviser l'ensemble de données en petits morceaux (partitions) qui peuvent être traités en parallèle sur les nœuds de travail du cluster. Notez que le partitionnement n'est pas applicable aux entités ODP.

Pour plus de détails, consultez [AWS Glue Spark et PySpark jobs](#).

Prérequis

Un objet SAP OData dont vous souhaitez lire un extrait. Vous aurez besoin du EntitySet nom ou de l'objet, `/sap/opu/odata/sap/API_SALES_ORDER_SRV/A_SalesOrder` par exemple.

Exemple

```
sapodata_read = glueContext.create_dynamic_frame.from_options(
    connection_type="SAPOData",
    connection_options={
```

```
"connectionName": "connectionName",
"ENTITY_NAME": "/sap/opu/odata/sap/API_SALES_ORDER_SRV/A_SalesOrder"
}, transformation_ctx=key)
```

Requêtes de partitionnement

Partitionnement basé sur le terrain

Vous pouvez fournir les options supplémentaires de Spark

`PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, et `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark. Les nombres entiers, les dates et `DateTime` les champs prennent en charge le partitionnement basé sur les champs dans le connecteur SAP. OData

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur de limite inférieure inclusive du champ de partition choisi.

Pour tout champ dont le type de données est `DateTime`, le format d'horodatage Spark utilisé dans les requêtes SQL Spark est accepté.

Exemples de valeurs valides : "2000-01-01T00:00:00.000Z"

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`: nombre de partitions.
- `PARTITION_BY`: le type de partitionnement à effectuer, `FIELD` à transmettre en cas de partitionnement basé sur le terrain.

Exemple

```
sapodata= glueContext.create_dynamic_frame.from_options(
    connection_type="sapodata",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "/sap/opu/odata/sap/SEPM_HCM_SCENARIO_SRV/EmployeeSet",
        "PARTITION_FIELD": "validStartDate"
        "LOWER_BOUND": "2000-01-01T00:00:00.000Z"
        "UPPER_BOUND": "2020-01-01T00:00:00.000Z"
        "NUM_PARTITIONS": "10",
        "PARTITION_BY": "FIELD"
```

```
}, transformation_ctx=key)
```

Partitionnement basé sur les enregistrements

La requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

Le partitionnement basé sur les enregistrements n'est pris en charge que pour les entités non ODP, car la pagination dans les entités ODP est prise en charge par le jeton ou le jeton de saut suivant.

- PARTITION_BY: le type de partitionnement à effectuer. COUNT doit être transmis en cas de partitionnement basé sur des enregistrements.

Exemple

```
sapodata= glueContext.create_dynamic_frame.from_options(  
    connection_type="sapodata",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "/sap/opu/odata/sap/SEPM_HCM_SCENARIO_SRV/EmployeeSet",  
        "NUM_PARTITIONS": "10",  
        "PARTITION_BY": "COUNT"  
    }, transformation_ctx=key)
```

Limitations/Appels

- Les entités ODP ne sont pas compatibles avec le partitionnement basé sur les enregistrements car la pagination est gérée à l'aide du jeton skip/du jeton delta. Par conséquent, pour le partitionnement basé sur les enregistrements, la valeur par défaut de MaxConcurrency est définie sur « null », quelle que soit la saisie par l'utilisateur.
- Lorsque la limite et la partition sont appliquées, la limite a priorité sur le partitionnement.

Options de OData connexion SAP

Les options de connexion pour SAP sont les OData suivantes :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans SAP OData.

Par exemple :/sap/opu/odata/sap/API_SALES_ORDER_SRV/A_SalesOrder

- **API_VERSION**(Chaîne) - (Facultatif) Utilisé pour la lecture. Version de l' OData API SAP Rest que vous souhaitez utiliser. Exemple : 2.0.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.

Exemples : SalesOrder

- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.

Par exemple : SalesOrder = "10"

- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

Par exemple : SELECT * FROM /sap/opu/odata/sap/API_SALES_ORDER_SRV/A_SalesOrder

- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.

Par exemple : ValidStartDate

- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.

Par exemple : "2000-01-01T00:00:00.000Z"

- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.

Par exemple : "2024-01-01T00:00:00.000Z"

- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.
- **INSTANCE_URL**(String) - URL de l'hôte de l'application de l'instance SAP.

Par exemple : https://example-externaldata.sierra.aws.dev

- **SERVICE_PATH**(String) - Le chemin du service d'application de l'instance SAP.

Par exemple : /sap/opu/odata/iwfnd/catalogservice;v=2

- **CLIENT_NUMBER**(String) - Numéro du client de l'application de l'instance SAP.

Par exemple : 100

- **PORT_NUMBER**(String) - Par défaut : numéro de port de l'application de l'instance SAP.

Par exemple : 443

- LOGON_LANGUAGE(String) - Langue de connexion à l'application de l'instance SAP.

Par exemple : EN

- ENABLE_CDC(String) - Définit s'il faut exécuter une tâche avec le CDC activé, c'est-à-dire avec le suivi des modifications.

Par exemple : True/False

- DELTA_TOKEN(String) - Exécute une extraction de données incrémentielle en fonction du jeton Delta valide fourni.

Par exemple : D20241107043437_000463000

- PAGE_SIZE(Entier) - Définit le format de page pour interroger les enregistrements. La taille de page par défaut est de 50 000. Lorsqu'une taille de page est spécifiée, SAP renvoie uniquement le nombre défini d'enregistrements par appel d'API, plutôt que l'ensemble de données complet. Le connecteur fournira toujours le nombre total d'enregistrements et gèrera la pagination en utilisant le format de page que vous avez spécifié. Si vous avez besoin d'une taille de page plus grande, vous pouvez choisir n'importe quelle valeur jusqu'à 500 000, qui est le maximum autorisé. Toute taille de page spécifiée supérieure à 500 000 sera ignorée. Le système utilisera plutôt le format de page maximal autorisé. Vous pouvez spécifier le format de page dans l' AWS Glue Studio interface utilisateur en ajoutant une option de connexion PAGE_SIZE avec la valeur souhaitée.

Par exemple : 20000

Détails de OData l'entité et du champ SAP

Entité	Type de données	Opérateurs pris en charge
Tables (entités dynamiques)	Chaîne	=, !=, >, >=, <, <=, ENTRE, COMME
	Entier	=, !=, >, >=, <, <=, ENTRE, COMME
	Long	=, !=, >, >=, <, <=, ENTRE, COMME

Entité	Type de données	Opérateurs pris en charge
	Double	=, !=, >, >=, <, <=, ENTRE, COMME
	Date	=, !=, >, >=, <, <=, ENTRE, COMME
	DateTime	=, !=, >, >=, <, <=, ENTRE, COMME
	Booléen	=, !=
	Struct	=, !=, >, >=, <, <=, ENTRE, COMME

Connexion à SendGrid

SendGrid est une plateforme de communication client pour les e-mails transactionnels et marketing.

- SendGrid Le connecteur aide à créer et à gérer des listes de contacts et à créer des campagnes de marketing par e-mail.
- SendGrid permet aux entreprises en ligne, aux organisations à but non lucratif et à d'autres entités en ligne de créer et d'envoyer des e-mails marketing à un large public et de surveiller l'engagement avec ces e-mails.

Rubriques

- [AWS Glue support pour SendGrid](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration SendGrid](#)
- [Configuration des SendGrid connexions](#)
- [Lecture à partir d' SendGrid entités](#)
- [SendGrid options de connexion](#)
- [SendGrid limites](#)

AWS Glue support pour SendGrid

AWS Glue prend en charge SendGrid les éléments suivants :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données à partir de SendGrid.

Soutenu en tant que cible ?

Non.

Versions SendGrid d'API prises en charge

Les versions SendGrid d'API suivantes sont prises en charge :

- v3

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration SendGrid

Avant de pouvoir AWS Glue transférer des données depuis SendGrid, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un SendGrid compte doté d'une clé API.
- Votre SendGrid compte dispose d'un accès à l'API avec une licence valide.

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre SendGrid compte. Pour les connexions classiques, vous n'avez rien d'autre à faire dans SendGrid.

Configuration des SendGrid connexions

SendGrid prend en charge l'authentification personnalisée.

Pour consulter SendGrid la documentation publique sur la génération des clés d'API requises pour une authentification personnalisée, consultez [Authentification](#).

Pour configurer une SendGrid connexion :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir le secret du consommateur de l'application connectée avec *api_key* comme clé.

- b. Remarque : vous devez créer un secret pour vos connexions dans AWS Glue.
1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez SendGrid.
 - b. Indiquez INSTANCE_URL l'instance SendGrid à laquelle vous souhaitez vous connecter.
 - c. Sélectionnez le rôle AWS IAM que AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire secretName.

Lecture à partir d' SendGrid entités

Prérequis

Un SendGrid objet que vous aimeriez lire. Vous aurez besoin du nom de l'objet tel que `lists`, `singlesends` ou `segments`.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Listes	Non	Oui	Non	Oui	Non
Envois uniques	Oui	Oui	Non	Oui	Non
Automatisation des statistiques des campagnes marketing	Oui	Oui	Non	Oui	Non
Statistiques de la campagne marketing - Single Sends	Oui	Oui	Non	Oui	Non
Segments	Oui	Non	Non	Oui	Non
Contacts	Oui	Non	Non	Oui	Non
Catégorie	Non	Non	Non	Oui	Non
Statistiques	Oui	Non	Non	Oui	Non
Groupes de désinscription	Oui	Non	Non	Oui	Non

Exemple :

```
sendgrid_read = glueContext.create_dynamic_frame.from_options(
    connection_type="sendgrid",
```

```

connection_options={
  "connectionName": "connectionName",
  "ENTITY_NAME": "lists",
  "API_VERSION": "v3",
  "INSTANCE_URL": "instanceUrl"
}

```

SendGrid détails de l'entité et du champ :

Entités avec métadonnées statiques :

Entité	Champ	Type de données	Opérateurs pris en charge	
Listes	id	Chaîne	N/A	
	name	Chaîne	N/A	
	nombre de contacts	Entier	N/A	
	_métadonnées	Struct	N/A	
Envois uniques	id	Chaîne	N/A	
	name	Chaîne	EQUAL_TO	
	abtest	Struct	N/A	
	status	Chaîne	EQUAL_TO	
	categories	Liste	EQUAL_TO	
	send_at	Chaîne	N/A	
	is_abtest	Booléen	N/A	
	updated_at	Chaîne	N/A	
	created_at	Chaîne	N/A	
	canaux	Liste	N/A	

Entité	Champ	Type de données	Opérateurs pris en charge	
Automatisation des statistiques des campagnes marketing	id	Chaîne	N/A	
	agrégation	Chaîne	N/A	
	step_id	Chaîne	N/A	
	stats	Struct	N/A	
	identifiants d'automatisation	Liste	EQUAL_TO	
Statistiques de la campagne marketing - Singlesends	id	Chaîne	N/A	
	ab_variation	Chaîne	N/A	
	ab_phase	Chaîne	N/A	
	agrégation	Chaîne	N/A	
	stats	Struct	N/A	
	singlesend_ids	Liste	EQUAL_TO	
Segments	id	Chaîne	N/A	
	name	Chaîne	N/A	
	version de la requête	Chaîne	N/A	
	nombre de contacts	Entier	N/A	
	sample_up dated_at	Chaîne	N/A	

Entité	Champ	Type de données	Opérateurs pris en charge	
	mise à jour de l'échantillon suivant	Chaîne	N/A	
	created_at	Chaîne	N/A	
	updated_at	Chaîne	N/A	
	identifiant_liste_parent	Chaîne	N/A	
	status	Struct	N/A	
	identifiant_liste_parents	Chaîne	EQUAL_TO	
	aucun identifiant de liste de parents	Booléen	EQUAL_TO	
Contacts	id	Chaîne	N/A	
	first_name	Chaîne	N/A	
	last_name	Chaîne	N/A	
	nom_unique	Chaîne	N/A	
	e-mail	Chaîne	N/A	
	courriel_alternatifs	Liste	N/A	
	address_line_1	Chaîne	N/A	
	address_line_2	Chaîne	N/A	
	city	Chaîne	N/A	

Entité	Champ	Type de données	Opérateurs pris en charge	
	État_province_région	Chaîne	N/A	
	country	Chaîne	N/A	
	postal_code	Chaîne	N/A	
	phone_number	Chaîne	N/A	
	whatsapp	Chaîne	N/A	
	ligne	Chaîne	N/A	
	facebook	Chaîne	N/A	
	identifiant_listes	Liste	N/A	
	custom_fields	Struct	N/A	
	created_at	Chaîne	N/A	
	updated_at	Chaîne	N/A	
	_métadonnées	Struct	N/A	
	event_timestamp	DateTime	BETWEEN	
Catégorie	categories	Liste	N/A	
Statistiques	date	Chaîne	N/A	
	stats	Liste	N/A	
	date_de_début	DateTime	EQUAL_TO, ENTRE	
	agrégé_par	Chaîne	EQUAL_TO	

Entité	Champ	Type de données	Opérateurs pris en charge	
Groupes de désinscription	id	Entier	EQUAL_TO	
	name	Chaîne	N/A	
	description	Chaîne	N/A	
	dernier_e mail_envoyé_at	Entier	N/A	
	est par défaut	Booléen	N/A	
	se désabonne	Entier	N/A	

Note

Les types de données Struct et List sont convertis en type de données String, et le type de DateTime données est converti en Timestamp dans la réponse des connecteurs.

Requêtes de partitionnement

SendGrid ne prend pas en charge le partitionnement basé sur des filtres ou le partitionnement basé sur des enregistrements.

SendGrid options de connexion

Les options de connexion suivantes sont disponibles pour SendGrid :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans SendGrid.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. SendGrid Version de l'API Rest que vous souhaitez utiliser.
- INSTANCE_URL(Chaîne) - (Obligatoire) Utilisé pour la lecture. URL d' SendGrid instance valide.
- SELECTED_FIELDS(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.

- `FILTER_PREDICATE(String)` - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- `QUERY(String)` - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

SendGrid limites

Les restrictions ou remarques suivantes concernent SendGrid :

- L'extraction incrémentielle n'est prise en charge que par l'entité Stats sur le `start_date` terrain et par l'entité Contact sur le `event_timestamp` terrain.
- La pagination n'est prise en charge que par les entités Statistiques des campagnes marketing (automatisations), Statistiques des campagnes marketing (envois uniques), Envois uniques et Listes.
- Pour l'entité Stats, `start_date` il s'agit d'un paramètre de filtre obligatoire.
- Une clé d'API à accès restreint ne peut pas prendre en charge l'accès en lecture pour l'API e-mail et les entités Stats. Utilisez une clé d'API avec accès complet. Pour plus d'informations, consultez la section [Présentation de l'API](#).

Connexion à ServiceNow

ServiceNow est une plateforme SaaS basée sur le cloud pour automatiser les flux de travail de gestion informatique. La ServiceNow plateforme s'intègre facilement à d'autres outils, permettant aux utilisateurs de gérer les projets, les équipes et les interactions avec les clients à l'aide de diverses applications et plug-ins. En tant qu'utilisateur ServiceNow, vous pouvez vous connecter AWS Glue à votre ServiceNow compte. Vous pouvez ensuite l'utiliser ServiceNow comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre ServiceNow des AWS services ou d'autres applications prises en charge.

Rubriques

- [AWS Glue support pour ServiceNow](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration ServiceNow](#)
- [Configuration des ServiceNow connexions](#)
- [Lecture à partir d' entités ServiceNow](#)
- [ServiceNow options de connexion](#)

- [Limitations et remarques relatives au ServiceNow connecteur](#)

AWS Glue support pour ServiceNow

AWS Glue prend en charge ServiceNow les éléments suivants :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données à partir de ServiceNow.

Soutenu en tant que cible ?

Non.

Versions ServiceNow d'API prises en charge

Les versions ServiceNow d'API suivantes sont prises en charge :

- v2

Pour la prise en charge des entités par version spécifique, voir Entités prises en charge pour la source.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

```
}  
]  
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration ServiceNow

Avant de pouvoir AWS Glue transférer des données depuis ServiceNow, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un ServiceNow compte avec e-mail et mot de passe. Pour de plus amples informations, veuillez consulter [Création d'un ServiceNow compte](#).
- Votre ServiceNow compte est activé pour accéder à l'API. Toute utilisation de l' ServiceNow API est disponible sans frais supplémentaires.

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre ServiceNow compte.

Création d'un ServiceNow compte

Pour créer un ServiceNow compte :


1. Accédez à la page d'inscription sur servicenow.com, entrez vos coordonnées, puis cliquez sur Continuer.
2. Lorsque vous recevez un code de vérification dans votre courrier recommandé, saisissez-le et choisissez Vérifier.
3. Configurez l'authentification multifactorielle ou ignorez de le faire.

Votre compte est créé et ServiceNow affiche votre profil.

Création d'une instance de ServiceNow développeur

Demandez une instance de développeur après vous être connecté à ServiceNow.

1. Sur la [page de ServiceNow connexion](#), saisissez les informations d'identification de votre compte.
2. Choisissez le programme ServiceNow pour développeurs.



3. Choisissez Request Instance en haut à droite.
4. Entrez vos responsabilités professionnelles. Indiquez que vous acceptez les conditions d'utilisation, puis choisissez Terminer la configuration.
5. Une fois l'instance créée, notez l'URL et les informations d'identification de votre instance.

Récupération des informations d'identification BasicAuth

Pour récupérer les informations d'authentification de base d'un compte gratuit :

1. Sur la [page de ServiceNow connexion](#), saisissez les informations d'identification de votre compte.
2. Sur la page d'accueil, choisissez la section Modifier le profil (coin supérieur droit) et choisissez Gérer le mot de passe de l'instance.
3. Récupérez les informations de connexion telles que le nom d'utilisateur, le mot de passe et l'URL de l'instance.

 Note

<username>Si l'authentification MFA est activée pour le compte, ajoutez le jeton MFA à la fin du mot de passe de l'utilisateur dans l'authentification de base : <password><MFA Token>

Pour plus d'informations, consultez la section [Création d'applications](#) dans la ServiceNow documentation.

Création d'informations d'identification OAuth 2.0

Pour utiliser OAuth2 .0 dans le ServiceNow connecteur, vous devez créer un client entrant) afin de générer l'ID client et le secret du client :

1. Sur la [page de ServiceNow connexion](#), saisissez les informations d'identification de votre compte.
2. Sur la page d'accueil, choisissez Commencer à construire.
3. Sur la page App Engine Studio, recherchez Application Registry.
4. Choisissez Nouveau en haut à droite.
5. Choisissez l'option Créer un point de terminaison d' OAuth API pour les clients externes.
6. Apportez les modifications nécessaires à la OAuth configuration et choisissez Mettre à jour.

Exemple d'URL de redirection : <https://us-east-1.console.aws.amazon.com/gluestudio/oauth>

7. Sélectionnez l'application OAuth cliente nouvellement créée pour récupérer l'ID client et le secret du client.
8. Stockez l'ID client et le secret du client pour un traitement ultérieur.

Pour configurer OAuth dans un compte de développeur hors production :

1. Créez un profil d'authentification à l'aide de la rubrique [Créer un profil d'authentification](#) de la ServiceNow documentation.

2. Dans le profil d'authentification pour OAuth, sélectionnez Type as OAuth et sélectionnez le client entrant créé ci-dessus pour définir l'OAuth entité.
3. S'il existe plusieurs clients, vous devez créer plusieurs profils d'authentification pour définir l' OAuth entité requise dans le profil d'authentification.
4. Si elle n'est pas configurée, créez une politique d'accès à l'API REST pour donner accès à l'API TABLE. Consultez la section [Créer une politique d'accès à l'API REST](#).

Configuration des ServiceNow connexions

Le type de subvention détermine le mode de AWS Glue communication avec ServiceNow lequel vous pouvez demander l'accès à vos données. Votre choix influe sur les exigences que vous devez respecter avant de créer la connexion. ServiceNow prend en charge uniquement le type de subvention AUTHORIZATION_CODE pour la version 2.0. OAuth

- Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers un serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. La AWS Glue console redirige l'utilisateur vers l' ServiceNow endroit où il doit se connecter et autorise AWS Glue les autorisations demandées pour accéder à son ServiceNow instance.
- Les utilisateurs peuvent toujours choisir de créer leur propre application connectée ServiceNow et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés ServiceNow vers pour se connecter et autoriser AWS Glue l'accès à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- Pour consulter ServiceNow la documentation publique sur la création d'une application connectée pour le OAuth flux de code d'autorisation, voir [Configuration OAuth](#).

Pour configurer une ServiceNow connexion :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'authentification de base, le secret doit contenir le secret du consommateur de l'application connectée avec USERNAME et PASSWORD comme clé.

- b. Pour un type d'octroi de code d'autorisation, le secret doit contenir le secret du consommateur de l'application connectée avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
 - c. Remarque : Vous devez créer un secret par connexion dans AWS Glue.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez ServiceNow.
 - b. Indiquez l'`INSTANCE_URL` de l' ServiceNow instance à laquelle vous souhaitez vous connecter.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez le type d'authentification que vous souhaitez utiliser pour cette connexion AWS Glue.
 - i. Authentification de base : ce type d'authentification fonctionne bien pour les scénarios d'automatisation car il permet d'utiliser le nom d'utilisateur et le mot de passe dès le départ avec les autorisations d'un utilisateur particulier dans l' ServiceNow instance. AWS Glue est capable d'utiliser le nom d'utilisateur et le mot de passe pour s'authentifier. ServiceNow APIs Entrez les entrées suivantes uniquement en cas d'authentification de base : `Username` et `Password`.

- ii. OAuth2: entrez les entrées suivantes uniquement en cas de
 OAuth2 :ClientId,ClientSecret,Authorization URL,Authorization Token URL.
 - e. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - f. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture à partir d' ServiceNow entités

Prérequis

Un objet ServiceNow Tables que vous souhaitez lire. Vous aurez besoin du nom de l'objet tel que pa_bucket ou incident.

Exemple :

```
servicenow_read = glueContext.create_dynamic_frame.from_options(
    connection_type="servicenow",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "pa_buckets",
        "API_VERSION": "v2"
        "instanceUrl": "https://<instance-name>.service-now.com"
    }
)
```

ServiceNow détails de l'entité et du champ :

Pour les entités suivantes, ServiceNow fournit des points de terminaison permettant de récupérer les métadonnées de manière dynamique, afin que le support des opérateurs soit capturé au niveau du type de données pour chaque entité.

Entité	Type de données	Opérateurs pris en charge
Tables (entités dynamiques)	Entier	=, !=, <, <=, >, >=, ENTRE
	BigDecimal	=, !=, <, <=, >, >=, ENTRE
	Float	=, !=, <, <=, >, >=, ENTRE

Entité	Type de données	Opérateurs pris en charge
	Long	=, !=, <, <=, >, >=, ENTRE
	Date	=, !=, <, <=, >, >=, ENTRE
	DateTime	=, !=, <, <=, >, >=, ENTRE
	Booléen	=, !=
	Chaîne	=, !=, <, <=, >, >=, ENTRE, COMME
	Struct	N/A

Note

Le type de données Struct est converti en type de données String dans la réponse du connecteur.

Note

DML_STATUS est un attribut supplémentaire défini par l'utilisateur utilisé pour le suivi des enregistrements CRÉÉS/MIS À JOUR.

Requêtes de partitionnement

Partitionnement des bases de terrain :

Vous pouvez fournir les options supplémentaires de Spark

PARTITION_FIELDLOWER_BOUND,UPPER_BOUND, et NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

Nom de l'entité	Champs de partitionnement	Type de données
Entité dynamique	sys_mod_count	Entier
	sys_created_on, sys_updated_on	DateTime

- **PARTITION_FIELD**: le nom du champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**: une valeur limite inférieure inclusive du champ de partition choisi.

Pour le champ Datetime, nous acceptons le format d'horodatage Spark utilisé dans SPark les requêtes SQL.

Exemples de valeurs valides :

```
"2024-01-30T06:47:51.000Z"
```

- **UPPER_BOUND**: une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**: le nombre de partitions.

Le tableau suivant décrit les détails relatifs à la prise en charge des champs de partitionnement des entités :

Exemple :

```
servicenow_read = glueContext.create_dynamic_frame.from_options(
    connection_type="servicenow",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "pa_buckets",
        "API_VERSION": "v2",
        "instanceUrl": "https://<instance-name>.service-now.com"
        "PARTITION_FIELD": "sys_created_on"
        "LOWER_BOUND": "2024-01-30T06:47:51.000Z"
        "UPPER_BOUND": "2024-06-30T06:47:51.000Z"
        "NUM_PARTITIONS": "10"
    }
)
```

Partitionnement basé sur des enregistrements :

Vous pouvez fournir l'option Spark supplémentaire `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ce paramètre, la requête d'origine est divisée en `NUM_PARTITIONS` plusieurs sous-requêtes qui peuvent être exécutées simultanément par les tâches Spark.

Dans le partitionnement basé sur les enregistrements, le nombre total d'enregistrements présents est demandé par l' `ServiceNow API`, puis divisé par le nombre fourni. `NUM_PARTITIONS` Le nombre d'enregistrements qui en résulte est ensuite extrait simultanément par chaque sous-requête.

- `NUM_PARTITIONS`: le nombre de partitions.

Exemple :

```
servicenow_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="servicenow",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "pa_buckets",  
        "API_VERSION": "v2",  
        "instanceUrl": "https://<instance-name>.service-now.com"  
        "NUM_PARTITIONS": "2"  
    }  
)
```

ServiceNow options de connexion

Les options de connexion suivantes sont disponibles pour `ServiceNow` :

- `ENTITY_NAME`(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans `ServiceNow`.
- `API_VERSION`(Chaîne) - (Obligatoire) Utilisé pour la lecture. `ServiceNow` Version de l'API Rest que vous souhaitez utiliser. Par exemple : v1, v2, v3, v4.
- `SELECTED_FIELDS`(Liste<String>) - Par défaut : vide (`SELECT *`). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- `FILTER_PREDICATE`(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- `QUERY`(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- `PARTITION_FIELD`(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi. Par exemple : 2024-01-30T 06:47:51.000 Z.

- UPPER_BOUND(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi. Par exemple : 2024-06-30T 06:47:51.000 Z.
- NUM_PARTITIONS(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire. Par exemple : 10.
- INSTANCE_URL(String) - (Obligatoire) Une URL d' ServiceNow instance valide au format https :// <instance-name>.service-now.com.

Limitations et remarques relatives au ServiceNow connecteur

Les limitations ou remarques suivantes concernent le ServiceNow connecteur :

- Selon la [documentation SaaS](#), sys_created_on, sys_updated_on, et sys_mod_count sont des champs générés par le système. Le connecteur s'appuie sur le SaaS APIs pour fournir ces champs dans le corps de réponse.
 - Si le SaaS ne génère ces champs pour aucune entité, le partitionnement basé sur des filtres ne peut pas être pris en charge.
- Si le SaaS APIs ne s'affiche pas sys_created_on et que sys_updated_on les champs de la réponse DML_STATUS ne peuvent pas être calculés.

Connexion à Slack en AWS Glue Studio

Slack est une application de communication d'entreprise qui permet aux utilisateurs d'envoyer des messages et des pièces jointes via différents canaux publics et privés. Si vous utilisez Slack, vous pouvez vous connecter AWS Glue à votre compte Slack. Vous pouvez ensuite utiliser Slack comme source de données dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre Slack et AWS des services ou d'autres applications prises en charge.

Rubriques

- [AWS Glue support pour Slack](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Slack](#)
- [Configuration des connexions Slack](#)
- [Lecture à partir d'entités Slack](#)
- [Options de connexion à Slack](#)

- [Limites](#)
- [Création d'un nouveau compte Slack et configuration de l'application cliente](#)

AWS Glue support pour Slack

AWS Glue prend en charge Slack comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Slack.

Soutenu en tant que cible ?

Non.

Versions de l'API Slack prises en charge

API Slack v2.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Vous pouvez également utiliser les politiques IAM gérées suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM et Amazon EC2. Amazon CloudWatch Logs Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Slack

Avant de pouvoir transférer des données AWS Glue vers ou depuis Slack, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous devez avoir un compte Slack. Pour de plus amples informations, veuillez consulter [Création d'un nouveau compte Slack et configuration de l'application cliente](#).

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Slack.

Configuration des connexions Slack

Slack prend en charge le type de AUTHORIZATION_CODE subvention pour OAuth 2.

Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. La AWS Glue console redirige l'utilisateur vers Slack où il doit se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Slack.

Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans Slack et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la

AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Slack pour se connecter et autoriser l'accès AWS Glue à leurs ressources.

Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès expire au bout d'une heure après sa création. Un nouveau jeton d'accès peut être récupéré à l'aide du jeton d'actualisation.

Pour plus d'informations sur la création d'une application connectée pour le OAuth flux de code d'autorisation, consultez l'[API Slack](#).

Pour configurer une connexion Slack :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes. Vous devez créer un secret pour la connexion dans AWS Glue.
 - a. Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET comme clé.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Slack.
 - b. Fournissez l'environnement Slack.
 - c. Sélectionnez le rôle IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

```
}
```

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture à partir d'entités Slack

Prérequis

- Un objet Slack dont vous souhaitez lire un extrait.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
conversations	Oui	Oui	Non	Oui	Oui

Exemple

```
slack_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="slack",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "conversations/C058W38R5J8"  
    }  
)
```

Informations sur les entités et les champs Slack

Entité	Champ	Type de données	Opérateurs pris en charge
conversations	pièces jointes	Liste	NA

Entité	Champ	Type de données	Opérateurs pris en charge
conversations	bot_id	Chaîne	NA
conversations	Blocs de	Liste	NA
conversations	client_msg_id	Chaîne	NA
conversations	est étoilé	Booléen	NA
conversations	dernière_lecture	Chaîne	NA
conversations	dernière_réponse	Chaîne	NA
conversations	réactions	Liste	NA
conversations	réponses	Liste	NA
conversations	nombre de réponses	Entier	NA
conversations	répondre_utilisateurs	Liste	NA
conversations	reply_users_count	Entier	NA
conversations	abonné	Booléen	NA
conversations	sous-type	Chaîne	NA
conversations	text	Chaîne	NA
conversations	équipe	Chaîne	NA
conversations	thread_ts	Chaîne	NA

Entité	Champ	Type de données	Opérateurs pris en charge
conversations	ts	Chaîne	ÉGAL À, ENTRE, INFÉRIEUR À, INFÉRIEUR À, INFÉRIEUR OU ÉGAL À, SUPÉRIEUR À, SUPÉRIEUR OU ÉGAL À
conversations	type	Chaîne	NA
conversations	utilisateur	Chaîne	NA
conversations	invitant	Chaîne	NA
conversations	racine	Struct	NA
conversations	est verrouillé	Booléen	NA
conversations	files	Liste	NA
conversations	salle	Struct	NA
conversations	charger	Booléen	NA
conversations	afficher en tant que robot	Booléen	NA
conversations	channel	Chaîne	NA
conversations	aucune notification	Booléen	NA
conversations	permalien	Chaîne	NA
conversations	épinglé	Liste	NA
conversations	info_épinglée	Struct	NA

Entité	Champ	Type de données	Opérateurs pris en charge
conversations	édité	Struct	NA
conversations	app_id	Chaîne	NA
conversations	bot_profile	Struct	NA
conversations	métadonnées	Struct	NA

Requêtes de partitionnement

Des options Spark supplémentaires `PARTITION_FIELD_LOWER_BOUND`, `UPPER_BOUND`, `NUM_PARTITIONS` peuvent être fournies si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur limite inférieure inclusive du champ de partition choisi.

Pour la date, nous acceptons le format de date Spark utilisé dans les requêtes SQL Spark.
Exemple de valeur valide : `"2024-07-01T00:00:00.000Z"`.

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`: nombre de partitions.

Les détails du support des champs de partitionnement par entité sont présentés dans le tableau ci-dessous.

Nom de l'entité	Champ de partitionnement	Type de données
conversations	ts	Chaîne

Exemple

```
slack_read = glueContext.create_dynamic_frame.from_options(
```

```
connection_type="slack",
connection_options={
    "connectionName": "connectionName",
    "ENTITY_NAME": "conversations/C058W38R5J8",
    "PARTITION_FIELD": "ts"
    "LOWER_BOUND": "2022-12-01T00:00:00.000Z"
    "UPPER_BOUND": "2024-09-23T15:00:00.000Z"
    "NUM_PARTITIONS": "2"
}
```

Options de connexion à Slack

Les options de connexion à Slack sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Nom de l'entité prise en charge. Exemple: conversations/C058W38R5J8.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Champs que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Limites

Les limites du connecteur Slack sont les suivantes :

- Le partitionnement basé sur les enregistrements n'est pas pris en charge car le connecteur ne fournit aucun moyen de récupérer le nombre total d'enregistrements (messages) disponibles dans une conversation donnée.

Création d'un nouveau compte Slack et configuration de l'application cliente

Création d'un compte Slack

1. Ouvrez la [page d'accueil de Slack](#) pour créer un compte.

2. Choisissez S'INSCRIRE AVEC UNE ADRESSE E-MAIL. Entrez votre adresse e-mail et choisissez Continuer.
3. Entrez le code à 6 caractères envoyé à votre adresse e-mail, il vous redirigera vers la création d'un espace de travail ou pour rejoindre un espace de travail existant.
4. Choisissez Créer un espace de travail pour créer un nouvel espace de travail. Il vous redirigera pour répondre à quelques questions dans le cadre du processus de configuration.
 - Nom de l'entreprise
 - Votre nom
 - Pour ajouter des collègues par e-mail
 - Sur quoi travaille votre équipe ? (Ce sera le nom de la chaîne)
5. Remplissez les champs de saisie correspondant à ces questions et poursuivez. Votre compte est maintenant prêt à être utilisé.

Création d'une application Slack pour développeurs

1. Connectez-vous à votre compte Slack et connectez-vous à votre espace de travail Slack.
2. Dans le menu de l'espace de travail, sélectionnez Outils et paramètres, puis sélectionnez Gérer les applications.
3. Dans le menu de la liste des applications Slack, sélectionnez Créer.
4. Sur la page Vos applications, sélectionnez Créer une application.
5. Sur la page Créer une application, sélectionnez À partir de zéro.
6. Dans la boîte de dialogue Name app & choose workspace qui s'ouvre, ajoutez un nom d'application et choisissez un espace de travail dans lequel déployer votre application. Sélectionnez ensuite Créer une application.
7. Notez votre identifiant client et votre secret affichés dans les informations d'identification de l'application
8. Dans la barre latérale OAuth & Permissions, accédez à Étendue et choisissez Ajouter une OAuth portée. Vous pouvez ajouter la redirection URLs vers votre application pour la configuration afin de générer automatiquement le bouton « Ajouter à Slack » ou de distribuer votre application. Faites défiler la page jusqu'à la URLs section Redirection, choisissez Ajouter une nouvelle URL de redirection et enregistrez.

9. Accédez ensuite à la section OAuth Tokens pour votre espace de travail, puis choisissez Installer dans l'espace de travail.
10. Dans la boîte de dialogue qui s'ouvre pour vous informer que l'application que vous avez créée demande l'autorisation d'accéder à l'espace de travail Slack auquel vous souhaitez la connecter, sélectionnez Autoriser.
11. Une fois l'opération terminée, la console affichera un écran OAuth Tokens pour votre espace de travail.
12. À partir de l'écran OAuth Jetons pour votre espace de travail, copiez et enregistrez le OAuth jeton que vous utiliserez pour vous connecter à AWS Glue
13. Ensuite, vous allez récupérer votre identifiant d'équipe Slack. Dans le menu de l'espace de travail Slack, sélectionnez Outils et paramètres, puis sélectionnez Gérer les applications. Vous trouverez votre identifiant d'équipe dans l'URL de la page qui s'ouvre.
14. Pour distribuer publiquement votre application, vous pouvez l'activer en vous rendant sur le bouton Gérer la distribution dans la barre latérale. Faites défiler la page jusqu'à la section Partagez votre application avec d'autres espaces de travail et choisissez Supprimer les informations codées en dur. Donnez votre consentement et choisissez Active Public Distribution.
15. Votre application est désormais distribuée au public. Pour accéder à l'entité APIs, l'application doit être ajoutée à chaque canal de l'espace de travail à partir duquel l'utilisateur souhaite accéder.
16. Connectez-vous à votre compte Slack et ouvrez l'espace de travail dont vous souhaitez accéder à la chaîne.
17. Dans l'espace de travail, ouvrez la chaîne à laquelle l'application souhaite accéder et choisissez le titre de la chaîne. Sélectionnez l'onglet Intégrations dans la fenêtre contextuelle et ajoutez l'application. De cette façon, l'application est intégrée au canal pour avoir accès à son API.

L'ID client OAuth 2.0 doit comporter une ou plusieurs redirections autorisées URLs. URLs Les redirections ont le format suivant :

 Note

Les redirections Appflow URLs sont sujettes à modification. Les redirections de publication URLs pour AWS Glue la plateforme sont disponibles. L'ID client et le secret client proviennent des paramètres de votre identifiant client OAuth 2.0.

L'URL de redirection peut être l'une des suivantes	
URL de redirection pour l'environnement Gamma	
https://us-west-2.console.aws.amazon.com/appflow/oauth	https://us-east-1.awsc-integ.aws.amazon.com/appflow/oauth
https://us-east-2.console.aws.amazon.com/appflow/oauth	
https://us-west-1.console.aws.amazon.com/appflow/oauth	
https://ap-south-1.console.aws.amazon.com/appflow/oauth	
https://ap-southeast-1.console.aws.amazon.com/appflow/oauth	
https://ap-southeast-2.console.aws.amazon.com/appflow/oauth	
https://ap-northeast-1.console.aws.amazon.com/appflow/oauth	
https://ap-northeast-2.console.aws.amazon.com/appflow/oauth	
https://ca-central-1.console.aws.amazon.com/appflow/oauth	
https://eu-central-1.console.aws.amazon.com/appflow/oauth	
https://eu-west-1.console.aws.amazon.com/appflow/oauth	

L'URL de redirection peut être l'une des suivantes	
URL de redirection pour l'environnement Gamma	
<code>https://eu-west-2.console.aws.amazon.com/appflow/oauth</code>	
<code>https://eu-west-3.console.aws.amazon.com/appflow/oauth</code>	
<code>https://sa-east-1.console.aws.amazon.com/appflow/oauth</code>	
<code>https://us-west-2.awsc-integ.aws.amazon.com/appflow/oauth</code>	
<code>https://af-south-1.console.aws.amazon.com/appflow/oauth</code>	

Connexion à Smartsheet

Smartsheet est un produit SaaS de gestion du travail et de collaboration. Smartsheet permet essentiellement aux utilisateurs d'utiliser des objets de type feuille de calcul pour créer, stocker et utiliser des données commerciales.

Rubriques

- [AWS Glue support pour Smartsheet](#)
- [Politiques contenant les opérations d'API pour la création et l'utilisation de connexions](#)
- [Configuration de Smartsheet](#)
- [Configuration des connexions Smartsheet](#)
- [Lecture à partir d'entités Smartsheet](#)
- [Options de connexion Smartsheet](#)
- [Création d'un compte Smartsheet](#)
- [Limites](#)

AWS Glue support pour Smartsheet

AWS Glue prend en charge Smartsheet comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger les données de Smartsheet.

Soutenu en tant que cible ?

Non

Versions de l'API Smartsheet prises en charge

v2.0

Politiques contenant les opérations d'API pour la création et l'utilisation de connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode précédente, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#) — Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM,

CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#) — Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Smartsheet

Avant de pouvoir AWS Glue effectuer un transfert depuis Smartsheet, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous avez un compte Smartsheet avec e-mail et mot de passe. Pour plus d'informations sur la création d'un compte, consultez la section [Création d'un compte Smartsheet](#).
- Votre compte Smartsheet dispose d'un accès API avec une licence valide.
- Votre compte Smartsheet propose un plan tarifaire Pro pour les Sheets entités et un plan tarifaire pour les entreprises avec le module complémentaire Event Reporting pour les Events entités.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Smartsheet. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Smartsheet.

Configuration des connexions Smartsheet

Smartsheet prend en charge le type de AUTHORIZATION_CODE subvention pour OAuth2.

Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Les utilisateurs peuvent choisir de créer leur propre application connectée dans Smartsheet et de fournir leur propre identifiant client et leur propre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Smartsheet pour se connecter et autoriser l'accès AWS Glue à leurs ressources.

Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.

[Pour consulter la documentation publique de Smartsheet sur la création d'une application connectée pour le flux AUTHORIZATION_CODE OAuth , consultez Smartsheet. APIs](#)

Pour configurer une connexion Smartsheet :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :

Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET comme clé.

 Note

Il est indispensable de créer un secret par connexion AWS Glue.

2. Dans le AWS Glue Studio, créez une connexion sous Connexions de données en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Smartsheet.
 - b. Indiquez `instanceUrl` le Smartsheet auquel vous souhaitez vous connecter.
 - c. Sélectionnez le rôle IAM pour lequel AWS Glue vous pouvez assumer et qui dispose des autorisations nécessaires pour effectuer les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

}

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture à partir d'entités Smartsheet

Prérequis

Un Smartsheet objet que vous aimeriez lire. Reportez-vous au tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Feuille de liste	Oui	Oui	Non	Oui	Non
Métadonnées des lignes	Oui	Oui	Non	Oui	Non
Métadonnées de la feuille	Non	Non	Non	Oui	Non
Données de la feuille	Oui	Oui	Oui	Oui	Non
Événement	Oui	Oui	Non	Oui	Non

Exemple

```
Smartsheet_read = glueContext.create_dynamic_frame.from_options(
    connection_type="smartsheet",
    connection_options={
```



```

    "connectionName": "connectionName",
    "ENTITY_NAME": "list-sheets",
    "API_VERSION": "2.0",
    "INSTANCE_URL": "https://api.smartsheet.com"
  })

```

Détails des entités et des champs Smartsheet

Entité	Champ	Type de données	Opérateurs pris en charge
Feuilles de liste	id	Long	NA
	Niveau d'accès	Chaîne	NA
	createdAt	DateTime	NA
	Modifié à	DateTime	NA
	name	Chaîne	NA
	permalien	Chaîne	NA
	Modifié depuis	DateTime	>=
	version	Entier	NA
	source	Struct	NA
Métadonnées des lignes	id	Long	NA
	Identifiant de la feuille	Long	NA
	Niveau d'accès	Chaîne	NA
	pièces jointes	Liste	NA
	columns	Liste	NA
	Format conditionnel	Chaîne	NA
	createdAt	DateTime	NA

Entité	Champ	Type de données	Opérateurs pris en charge
	Créé par	Struct	NA
	discussions	Liste	NA
	preuves	Struct	NA
	agrandie	Booléen	NA
	Filtré	Booléen	NA
	format	Chaîne	NA
	inCriticalPath	Booléen	NA
	verrouillé	Booléen	NA
	lockedForUser	Booléen	NA
	Modifié à	DateTime	NA
	Modifié par	Struct	NA
	permalien	Chaîne	NA
	Numéro de ligne	Entier	NA
	version	Entier	NA
	totalRowCount	Entier	NA
	rowsModifiedSince	DateTime	>
	ID du filtre	Long	"="
	Identifiant du frère ou de la sœur	Long	NA
	Identifiant du parent	Long	NA

Entité	Champ	Type de données	Opérateurs pris en charge
Métadonnées de la feuille	id	Long	NA
	À partir de l'ID	Long	NA
	ownerId	Long	NA
	Niveau d'accès	Chaîne	NA
	pièces jointes	Liste	NA
	columns	Liste	NA
	createdAt	DateTime	NA
	crossSheetReferences	Liste	NA
	Dépendances activées	Booléen	NA
	discussions	Liste	NA
	effectiveAttachmentOptions	Liste	NA
	favori	Booléen	NA
	Gantt activé	Booléen	NA
	hasSummaryFields	Booléen	NA
	Modifié à	DateTime	NA
	name	Chaîne	NA
	owner	Chaîne	NA
	permalien	Chaîne	NA

Entité	Champ	Type de données	Opérateurs pris en charge
	Réglages du projet	Struct	NA
	readOnly	Booléen	NA
	resourceManagement Enabled	Booléen	NA
	showParentRowsForFilters	Booléen	NA
	source	Struct	NA
	récapitulatif	Struct	NA
	totalRowCount	Entier	NA
	Autorisations utilisateur	Struct	NA
	Réglages utilisateur	Struct	NA
	version	Entier	NA
	espace de travail	Struct	NA
	filtres	Liste	NA
	Configuration du Gantt	Struct	NA
	resourceManagement Type	Chaîne	NA
	cellImageUploadActivé	Booléen	NA
	isMultiPicklistActivé	Booléen	NA

Entité	Champ	Type de données	Opérateurs pris en charge
Événements	eventId	Chaîne	NA
	objectType	Chaîne	NA
	action	Chaîne	NA
	objectId	Long	NA
	Horodatage de l'événement	DateTime	NA
	userId	Long	NA
	requestUserId	Long	NA
	accessTokenName	Chaîne	NA
	source	Chaîne	NA
	Détails supplémentaires	Struct	NA
	since	DateTime	>=

Entités dotées de métadonnées dynamiques :

Pour l'entité suivante, Smartsheet fournit un point de terminaison permettant de récupérer les métadonnées de manière dynamique, ce qui permet de capturer le support des opérateurs au niveau du type de données.

Entité	Type de données	Opérateurs pris en charge
Données de la feuille	Chaîne	NA
Données de la feuille	Long	"="
Données de la feuille	Entier	NA

Entité	Type de données	Opérateurs pris en charge
Données de la feuille	DateTime	>

Exemple

```
Smartsheet_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="smartsheet",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "list-sheets",  
        "API_VERSION": "2.0",  
        "INSTANCE_URL": "https://api.smartsheet.com"  
    }  
)
```

Options de connexion Smartsheet

Les options de connexion pour Smartsheet sont les suivantes :

- **ENTITY_NAME**(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Smartsheet.
- **API_VERSION**(Chaîne) — (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Smartsheet Rest que vous souhaitez utiliser. Par exemple : v2.0.
- **INSTANCE_URL**(Chaîne) — (Obligatoire) Utilisé pour la lecture. URL de l'instance Smartsheet.
- **SELECTED_FIELDS**(Liste<String>) — Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) — Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) — Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

Création d'un compte Smartsheet

1. Ouvrez un compte Smartsheet en accédant à la page d'inscription [Smartsheet](#).
2. Choisissez Créer un compte pour créer un nouveau compte ou connectez-vous à l'aide de votre compte Google, Microsoft ou Apple enregistré.
- 3.

- 4.
5. Ouvrez l'e-mail de confirmation envoyé par Smartsheet, puis cliquez sur le lien de confirmation pour vérifier votre compte.

Vous serez abonné au plan d'essai par défaut.

6. Dans le coin inférieur gauche, cliquez sur l'icône du compte, puis sur Ajouter des licences/une mise à niveau pour améliorer votre plan tarifaire.

 Note

Cela est nécessaire pour accéder à Event Reporting, qui est un module complémentaire du plan Enterprise.

7. Dans le cadre du plan Enterprise, choisissez Contactez-nous pour demander une mise à niveau de compte auprès de l'équipe d'assistance.
8. Dans le formulaire de demande d'assistance, fournissez les informations requises et vos exigences pour mettre à niveau le plan.

Ceci termine la mise à niveau vers le plan Enterprise.

Création d'OAuth2.0 informations d'identification

1. Après avoir mis à niveau le plan tarifaire de votre compte pour accéder aux outils de développement, accédez aux [développeurs Smartsheet](#).

Vous recevrez un e-mail d'activation.

2. Ouvrez un e-mail d'activation envoyé par Smartsheet et choisissez le lien d'activation pour activer les outils de développement sur votre compte.

L'outil pour développeurs vous permet de créer l'application.

3. Ouvrez la page d'accueil de votre compte Smartsheet et sélectionnez Compte pour vérifier l'accès.
4. Choisissez Developer Tools dans la liste des services, puis entrez les détails du profil du développeur.
5. Choisissez Créer une nouvelle application.
6. Entrez les informations suivantes dans le formulaire d'inscription à l'application :

- Nom : nom de l'application.
- Description : description de l'application.
- URL : URL qui vous permet de lancer votre application ou URL de la page de destination.
- Contact/support : coordonnées de l'équipe d'assistance.
- URL de redirection : URL (également appelée URL de rappel) de votre application qui recevra les informations d'identification [OAuth 2.0](#).

7. Choisissez Save (Enregistrer).

Smartsheet attribue un identifiant client et un secret client à votre application. Enregistrez ces valeurs pour les étapes suivantes. Vous pourrez également les consulter à nouveau ultérieurement dans la section Outils de développement.

Limites

Smartsheet ne prend pas en charge le partitionnement basé sur les champs ou les enregistrements.

Connexion aux publicités Snapchat dans AWS Glue Studio

Snapchat est une application et un service de messagerie instantanée multimédia développés par Snap Inc., à l'origine Snapchat Inc. L'une des principales caractéristiques de Snapchat est que les photos et les messages ne sont généralement disponibles que pendant une courte période avant de devenir inaccessibles à leurs destinataires. Le marketing Snapchat est une publication pour laquelle les entreprises peuvent payer pour être diffusées aux utilisateurs de Snapchat.

Rubriques

- [AWS Glue support pour Snapchat Ads](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration des publicités Snapchat](#)
- [Configuration des connexions Snapchat Ads](#)
- [Lecture depuis les entités Snapchat Ads](#)
- [Options de connexion à Snapchat Ads](#)
- [Création d'un compte Snapchat Ad et configuration de l'application cliente](#)
- [Création d'une application dans votre compte Snapchat Ads](#)

AWS Glue support pour Snapchat Ads

AWS Glue prend en charge les publicités Snapchat comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Snapchat Ads.

Soutenu en tant que cible ?

Non.

Versions de l'API Snapchat Ads prises en charge

v1.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les AWS autorisations requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Vous pouvez également utiliser les politiques IAM gérées suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM et Amazon EC2. Amazon CloudWatch Logs Si vous suivez la convention de dénomination des

ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration des publicités Snapchat

Avant de pouvoir AWS Glue effectuer un transfert depuis Snapchat Ads, vous devez remplir les conditions suivantes :

Configuration requise

- Vous avez un compte Snapchat Ads. Pour plus d'informations sur la création d'un compte, voir [Création d'un compte Snapchat Ad et configuration de l'application cliente](#) .
- Vous avez créé une OAuth2 application dans votre compte Snapchat Ads. Cette intégration fournit les informations d'identification qui AWS Glue permettent d'accéder à vos données en toute sécurité lorsqu'elle passe des appels authentifiés vers votre compte. Pour de plus amples informations, veuillez consulter [Création d'une application dans votre compte Snapchat Ads](#) .

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Snapchat Ads. Dans Snapchat Ads, une application connectée est un framework qui autorise des applications externes, par exemple AWS Glue, à accéder à vos données Snapchat Ads.

Configuration des connexions Snapchat Ads

Snapchat Ads ne prend en charge que le type de AUTHORIZATION_CODE subvention.

Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers le serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. L'utilisateur qui crée une connexion peut par défaut s'appuyer sur une application connectée qu'il AWS Glue possède (application cliente AWS Glue gérée) sur laquelle il n'a pas besoin de fournir d'informations OAuth connexes, à l'exception de l'URL de son instance Snapchat Ads. La AWS Glue console redirigera l'utilisateur vers Snapchat Ads où il

devra se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Snapchat Ads.

Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans Snapchat Ads et de fournir leur propre identifiant client et leur secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Snapchat Ads pour se connecter et autoriser AWS Glue l'accès à leurs ressources.

Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès expire au bout d'une heure après sa création. Un nouveau jeton d'accès peut être récupéré à l'aide du jeton d'actualisation.

Pour plus d'informations sur la création d'une application connectée pour le OAuth flux de code d'autorisation, consultez la section [API des annonces](#).

Pour configurer une connexion Snapchat Ads, procédez comme suit :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes. Il est nécessaire de créer un secret pour chaque connexion dans AWS Glue.
 - a. Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Snapchat Ads.
 - b. Fournissez l'environnement Snapchat Ads.
 - c. Sélectionnez le rôle IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
```

```

        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
    ],
    "Resource": "*"
}
]
}

```

d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.

e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.

3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture depuis les entités Snapchat Ads

Prérequis

- Un objet publicitaire Snapchat dont vous souhaitez lire un extrait. Consultez le tableau des entités prises en charge ci-dessous pour vérifier les entités disponibles.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Organisation	Non	Non	Non	Oui	Non
Compte publicitaire	Non	Non	Non	Oui	Non
Créatif	Non	Non	Non	Oui	Non
Multimédia	Non	Non	Non	Oui	Non
Campagne	Oui	Non	Non	Oui	Non
Annonce sous un	Oui	Non	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
compte publicitaire					
Publicité en cours de campagne	Non	Non	Non	Oui	Non
Équipe publicitaire	Oui	Non	Non	Oui	Non
Segment	Non	Non	Non	Oui	Non

Exemple

```

snapchatads_read = glueContext.create_dynamic_frame.from_options(
    connection_type="snapchatAds",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "organization",
        "API_VERSION": "v1"
    }
)

```

Détails de l'entité et du champ Snapchat Ads

Snapchat Ads charge dynamiquement les champs disponibles sous l'entité sélectionnée. Selon le type de données du champ, il prend en charge les opérateurs de filtre suivants.

Type de données de champ	Opérateurs de filtre pris en charge
Booléen	=

Requêtes de partitionnement

- Partitionnement basé sur le champ : non pris en charge.

- Partitionnement basé sur les enregistrements : non pris en charge.

Options de connexion à Snapchat Ads

Les options de connexion pour Snapchat Ads sont les suivantes :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Nom de l'entité Snapchat Ads.
Exemple: `campaign` .
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Snapchat Ads Rest que vous souhaitez utiliser. La valeur sera v1, car Snapchat Ads ne prend actuellement en charge que la version v1.
- SELECTED_FIELDS(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Liste des colonnes séparées par des virgules que vous souhaitez sélectionner pour l'entité sélectionnée.
- FILTER_PREDICATE(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- QUERY(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

Création d'un compte Snapchat Ad et configuration de l'application cliente

Rubriques

- [Inscrivez-vous à Snapchat Ads](#)
- [Étapes pour créer un compte Snapchat Ad](#)

Inscrivez-vous à Snapchat Ads

Pour vous inscrire à Snapchat Ads, procédez comme suit :

1. Accédez au [gestionnaire de publicités Snapchat](#). Choisissez S'inscrire à côté de Nouveau sur Snapchat ? .
2. Sur l'écran de création de compte, suivez les instructions pour saisir le nom de votre entreprise, votre e-mail, votre mot de passe, etc. Choisissez Suivant.
3. Sur l'écran Créer votre profil, entrez des valeurs pour le nom d'utilisateur, le site Web (facultatif), puis choisissez Créer un compte. Cela vous donnera la possibilité d'ajouter une photo de profil et une biographie sur l'écran Modifier votre profil. Choisissez Confirmer.

4. Sur l'écran Informations commerciales, remplissez les champs obligatoires tels que le pays, la devise, le numéro de téléphone, le code GSTIN, etc., et terminez le processus de création du compte en choisissant Suivant.

Étapes pour créer un compte Snapchat Ad

Pour créer un compte Snapchat Ad, procédez comme suit :

1. Connectez-vous au gestionnaire de publicités. Cliquez ensuite sur le menu de navigation dans le coin supérieur et sélectionnez Comptes publicitaires.
2. Choisissez + Nouveau compte publicitaire. Entrez les informations de votre annonceur :
 - Indiquez si vous êtes une agence qui achète des publicités pour le compte d'un annonceur. Si vous sélectionnez « Oui », votre annonce peut être rejetée si elle utilise des paramètres de ciblage tels que le ciblage par âge, sexe ou code postal. Le ciblage relatif à l'âge minimum peut être appliqué jusqu'à 21 ans.
 - Indiquez si votre compte publicitaire diffusera ou non des annonces de logement, de crédit ou d'emploi. Si vous sélectionnez « Oui », votre annonce peut être rejetée si elle utilise des paramètres de ciblage tels que le ciblage par âge, sexe ou code postal. Le ciblage relatif à l'âge minimum peut être appliqué jusqu'à 21 ans.
 - Indiquez si vous souhaitez utiliser le compte publicitaire pour les annonces politiques. Si vous diffusez une annonce politique, indiquez l'organisation politique ou le groupe de défense qui finance la publicité. Si vous ne saisissez pas correctement l'organisation politique, vos annonces risquent d'être rejetées. Vous devrez également remplir le « formulaire d'évaluation des annonces politiques » obligatoire avant de soumettre des annonces.
3. Choisissez Détails du compte et renseignez les informations de votre compte publicitaire :

Champ	Description
Nom	Le nom de votre compte publicitaire.
Type de compte	Sélectionnez votre type de compte, s'il n'est pas renseigné automatiquement.
Type de facturation	Si vous souhaitez avoir accès en permanence à votre source de financement, choisissez « Revolving ». Cela vous permet de

Champ	Description
	réapprovisionner votre marge de crédit et cette option est souvent choisie pour diffuser des annonces dans le gestionnaire de publicités. Si vous préférez lancer une campagne ponctuelle avec un plafond de dépenses, vous pouvez choisir l'ordre d'insertion. Si vous créez un compte avec un ordre d'insertion, mais que vous souhaitez fixer un plafond de dépenses ultérieurement, vous pouvez laisser le plafond de dépenses à 0\$. De cette façon, le compte aura une limite de dépenses de 0\$, mais vous pourrez en appliquer une plus tard.
Organisation de publicité	L'organisation qui achète des publicités.
Centre de facturation	Choisissez le centre de facturation auquel vous souhaitez recevoir des factures. Vous pouvez utiliser celui créé automatiquement lorsque vous avez revendiqué votre entreprise pour la première fois ou ajouter un autre centre de facturation en suivant les étapes du centre d'aide aux entreprises .
Devise	Choisissez votre devise.
Plafond de dépenses	Si vous avez choisi « Ordre d'insertion » comme type de facturation, saisissez le budget d'un compte publicitaire.
Fuseau horaire	Sélectionnez votre fuseau horaire.

- Choisissez Créer un compte. Votre compte publicitaire sera créé et vous le trouverez dans la section Comptes publicitaires du Gestionnaire de publicités. Pour commencer à lancer

des annonces, vous devez saisir un mode de paiement. Vous pouvez également ajouter des membres à votre compte publicitaire.

- Indiquez si vous souhaitez utiliser un paiement existant ou en créer un nouveau. Choisissez ensuite Enregistrer le mode de paiement.
- Sélectionnez les [membres que vous avez invités](#) à rejoindre votre entreprise pour les ajouter au compte publicitaire. Pour plus d'informations sur les rôles et les autorisations qui peuvent être attribués, consultez la section [Vue d'ensemble des rôles et des autorisations](#). Les membres ajoutés pourront ensuite se connecter au gestionnaire de publicités et accéder à ce compte publicitaire. Lorsque vous avez terminé, sauvegardez vos membres.

Pour plus d'informations sur les comptes publicitaires, consultez https://businesshelp.snapchat.com/s/article/roles-permissions?language=en_US https://businesshelp.snapchat.com/s/article/roles-permissions?language=fr_US

Création d'une application dans votre compte Snapchat Ads

Pour activer l'accès à l'API marketing de Snapchat, assurez-vous d'avoir configuré un compte professionnel. Suivez ensuite les étapes ci-dessous.

- Connectez-vous au gestionnaire de publicités. Choisissez ensuite le menu dans le coin supérieur gauche et sélectionnez Business Dashboard, puis sélectionnez Business Details.
- Choisissez + OAuth App.
- Entrez le nom de votre application et ajoutez l'URL suivante en tant qu'URI de redirection Snap `https://<aws-region>.console.aws.amazon.com/gluestudio/oauth`. Par exemple, si vous utilisez la région us-west-1, l'URL serait `https://us-west-1.console.aws.amazon.com/gluestudio/oauth`) and choose **Create OAuth App** Choisissez Create OAuth App.
- Les informations d'identification de votre application (ID client et secret client) seront affichées. Enregistrez-les car ils seront nécessaires pour créer une connexion.

Connexion à Snowflake dans AWS Glue Studio

Note

Vous pouvez utiliser ... AWS Glue pour que Spark puisse lire et écrire dans les tables de Snowflake dans AWS Glue Versions 4.0 et ultérieures. Pour configurer une connexion Snowflake avec AWS Glue emplois programmés, voir [Connexions Redshift](#).

AWS Glue fournit un support intégré pour Snowflake. AWS Glue Studio fournit une interface visuelle pour se connecter à Snowflake, créer des tâches d'intégration de données et les exécuter sur le AWS Glue Studio environnement d'exécution Spark sans serveur.

AWS Glue Studio crée une connexion unifiée pour Snowflake. Pour de plus amples informations, veuillez consulter [Considérations](#).

Rubriques

- [Création d'une connexion Snowflake](#)
- [Création d'un nœud source Snowflake](#)
- [Création d'un nœud cible Snowflake](#)
- [Options avancées](#)

Création d'une connexion Snowflake

Note

Les connexions unifiées (connexion v2) normalisent toutes les connexions à utiliser `USERNAME`, ainsi que les `PASSWORD` clés pour les informations d'authentification de base. Vous pouvez toujours créer une connexion v1 via l'API avec des secrets contenant `sfUser`, `sfPassword`.

Lors de l'ajout d'une source de données - nœud Snowflake dans AWS Glue Studio, vous pouvez choisir une connexion AWS Glue Snowflake existante ou créer une nouvelle connexion. Vous devez choisir un type de connexion `SNOWFLAKE` et non un type de connexion `JDBC` configuré pour se connecter à Snowflake. Suivez la procédure suivante pour créer une connexion AWS Glue Snowflake :

Pour créer une connexion Snowflake

1. Dans Snowflake, générez un utilisateur *snowflakeUser* et un mot de passe. *snowflakePassword*
2. Déterminez avec quel entrepôt Snowflake cet utilisateur va interagir, *snowflakeWarehouse*. Vous pouvez le DEFAULT_WAREHOUSE définir comme forme *snowflakeUser* dans Snowflake ou vous en souvenir pour l'étape suivante.
3. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification Snowflake. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour *snowflakeUser* avec la clé. sfUser
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour *snowflakePassword* avec la clé. sfPassword
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour *snowflakeWarehouse* avec la clé. sfWarehouse Cela n'est pas nécessaire si une paire par défaut est définie dans Snowflake.
4. Dans le catalogue de AWS Glue données, créez une connexion en suivant les étapes décrites dans [Ajouter une AWS Glue connexion](#). Après avoir créé la connexion, conservez le nom de la connexion pour l'étape suivante. *connectionName*
 - Lorsque vous sélectionnez un type de connexion, sélectionnez Snowflake.
 - Lorsque vous sélectionnez URL Snowflake, indiquez le nom d'hôte de votre instance Snowflake. L'URL utilisera un nom d'hôte sous la forme *account_identifieur*.snowflakecomputing.com.
 - Lorsque vous sélectionnez un AWS secret, indiquez-le *secretName*.

Création d'un nœud source Snowflake

Autorisations nécessaires

AWS Glue Studio les tâches utilisant des sources de données Snowflake nécessitent des autorisations supplémentaires. Pour plus d'informations sur la façon d'ajouter des autorisations aux tâches ETL, consultez [Review IAM permissions needed for ETL jobs](#).

SNOWFLAKE AWS Glue les connexions utilisent un AWS Secrets Manager secret pour fournir des informations d'identification. Vos rôles de prévisualisation des tâches et des données AWS Glue Studio doivent être autorisés à lire ce secret.

Ajout d'une source de données Snowflake

Prérequis :

- Un AWS Secrets Manager secret pour vos identifiants Snowflake
- Une connexion au catalogue de AWS Glue données de type Snowflake

Pour ajouter un nœud Source de données – Snowflake :

1. Choisissez la connexion pour votre source de données Snowflake. Cela suppose que la connexion existe déjà et que vous pouvez la sélectionner parmi les connexions existantes. Si vous devez créer une connexion, choisissez Créer une connexion Snowflake. Pour en savoir plus, consultez [Overview of using connectors and connections](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés. Les informations relatives à la connexion sont visibles, notamment l'URL, les groupes de sécurité, le sous-réseau, la zone de disponibilité, la description et les horodatages de création (UTC) et de dernière mise à jour (UTC).

2. Choisissez une option de source Snowflake :
 - Choisir une seule table : il s'agit de la table qui contient les données auxquelles vous souhaitez accéder à partir d'une seule table Snowflake.
 - Saisir une requête personnalisée : vous permet d'accéder à un jeu de données à partir de plusieurs tables Snowflake en fonction de votre requête personnalisée.
3. Si vous avez choisi une seule table, saisissez le nom d'un schéma Snowflake.

Vous pouvez également choisir Saisir une requête personnalisée. Choisissez cette option pour accéder à un jeu de données personnalisé à partir de plusieurs tables Snowflake. Lorsque vous choisissez cette option, saisissez la requête Snowflake.

4. Dans les options Performance et sécurité (facultatif),
 - Activer le pushdown de requêtes : choisissez cette option si vous souhaitez télécharger le travail vers l'instance Snowflake.

5. Dans Propriétés Snowflake personnalisées (facultatif), saisissez les paramètres et les valeurs nécessaires.

Création d'un nœud cible Snowflake

Autorisations nécessaires

AWS Glue Studio les tâches utilisant des sources de données Snowflake nécessitent des autorisations supplémentaires. Pour plus d'informations sur la façon d'ajouter des autorisations aux tâches ETL, consultez [Review IAM permissions needed for ETL jobs](#).

SNOWFLAKE AWS Glue les connexions utilisent un AWS Secrets Manager secret pour fournir des informations d'identification. Vos rôles de prévisualisation des tâches et des données AWS Glue Studio doivent être autorisés à lire ce secret.

Ajout d'une cible de données Snowflake

Pour créer un nœud cible Snowflake :

1. Choisissez une table Snowflake existante comme cible ou saisissez un nouveau nom de table.
 2. Lorsque vous utilisez le nœud cible Cible de données – Snowflake, vous pouvez choisir l'une des options suivantes :
- APPREND : si une table existe déjà, insérez toutes les nouvelles données dans la table sous forme d'insertion. Si la table n'existe pas, créez-la, puis insérez toutes les nouvelles données.
 - FUSIONNER — AWS Glue mettra à jour ou ajoutera des données à votre table cible en fonction des conditions que vous spécifiez.

Choisissez parmi les options :

- Choisir des clés et des actions simples : choisissez les colonnes à utiliser comme clés de correspondance entre les données source et votre jeu de données cible.

Spécifiez les options suivantes lorsqu'elles correspondent :

- Mettez à jour l'enregistrement dans votre jeu de données cible avec les données de la source.
- Supprimez l'enregistrement dans votre jeu de données cible.

Spécifiez les options suivantes lorsqu'elles ne correspondent pas :

- Insérez les données source en tant que nouvelle ligne dans votre jeu de données cible.

- Ne rien faire.
- Saisir une instruction MERGE personnalisée : vous pouvez ensuite choisir Valider l'instruction de fusion pour vérifier si l'instruction est valide ou non.
- TRUNCATE : si une table existe déjà, tronquez les données de la table en effaçant d'abord le contenu de la table cible. Si la troncature est réussie, insérez toutes les données. Si la table n'existe pas, créez-la, puis insérez toutes les nouvelles données. Si la troncature échoue, l'opération échouera.
- DROP : si une table existe déjà, supprimez les métadonnées et les données de la table. Si la suppression est réussie, insérez toutes les données. Si la table n'existe pas, créez-la, puis insérez toutes les nouvelles données. Si la suppression échoue, l'opération échouera.

Options avancées

Consultez la section [Connexions Snowflake](#) dans le guide du AWS Glue développeur.

Connexion à Stripe dans AWS Glue Studio

Stripe est une plateforme de traitement des paiements en ligne et de traitement des cartes de crédit destinée aux entreprises. La plateforme Stripe permet aux entreprises d'accepter les paiements en ligne, de créer un abonnement (facturation récurrente) pour leur commerce électronique et de configurer un compte arrière pour recevoir les paiements. Stripe prend également en charge les paiements multipartites, dans lesquels elle permet aux entreprises de configurer leur place de marché et de collecter les paiements, puis de les verser aux vendeurs ou aux fournisseurs de services via un compte « connecté ».

Rubriques

- [AWS Glue support pour Stripe](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Stripe](#)
- [Configuration des connexions Stripe](#)
- [Lecture à partir d'entités Stripe](#)
- [Options de connexion Stripe](#)
- [Limites](#)
- [Création d'un nouveau compte Stripe et configuration de l'application cliente](#)

AWS Glue support pour Stripe

AWS Glue prend en charge Stripe comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Stripe.

Soutenu en tant que cible ?

Non

Versions de l'API Slack prises en charge

v1.

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Vous pouvez également utiliser les politiques IAM gérées suivantes pour autoriser l'accès :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM

et Amazon EC2. Amazon CloudWatch Logs Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Stripe

Avant de pouvoir AWS Glue transférer des données depuis Stripe, vous devez satisfaire aux exigences suivantes :

Configuration requise

- Vous devez avoir un compte Stripe avec e-mail et mot de passe. Pour de plus amples informations, veuillez consulter [Création d'un nouveau compte Stripe et configuration de l'application cliente](#).
- Votre compte Stripe est activé pour accéder à l'API. Toute utilisation de l'API Stripe est disponible sans frais supplémentaires.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Stripe.

Configuration des connexions Stripe

Stripe prend en charge l'authentification personnalisée. Pour plus d'informations sur la génération des clés d'API requises pour une autorisation personnalisée, consultez la [documentation de l'API STRIPE REST](#).

Pour configurer une connexion Stripe :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes. Il est nécessaire de créer un secret pour chaque connexion dans AWS Glue.
 - a. Pour une application connectée gérée par le client, Secret doit contenir l'application connectée Consumer Secret avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.

2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Stripe.
 - b. Sélectionnez le rôle IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- c. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - d. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture à partir d'entités Stripe

Prérequis

- Un objet Stripe à partir duquel vous souhaitez lire.

Entités prises en charge

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Équilibre	Non	Non	Non	Oui	Non
Transactions de solde	Oui	Oui	Non	Oui	Oui
Frais	Oui	Oui	Non	Oui	Oui
Litiges	Oui	Oui	Non	Oui	Oui
Liens vers des fichiers	Oui	Oui	Non	Oui	Oui
PaymentIntents	Oui	Oui	Non	Oui	Oui
SetupIntents	Oui	Oui	Non	Oui	Oui
Versements	Oui	Oui	Non	Oui	Oui
Remboursements	Oui	Oui	Non	Oui	Oui
Produits	Oui	Oui	Non	Oui	Oui
Les prix	Oui	Oui	Non	Oui	Oui
Coupons	Oui	Oui	Non	Oui	Oui
Codes promotionnels	Oui	Oui	Non	Oui	Oui
Codes fiscaux	Non	Oui	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Taux d'imposition	Oui	Oui	Non	Oui	Oui
Tarifs d'expédition	Oui	Oui	Non	Oui	Oui
Séances	Oui	Oui	Non	Oui	Oui
Notes de crédit	Oui	Oui	Non	Oui	Oui
Client	Oui	Oui	Non	Oui	Oui
Factures	Oui	Oui	Non	Oui	Oui
Articles de facture	Oui	Oui	Non	Oui	Non
Plans	Oui	Oui	Non	Oui	Oui
Citations	Oui	Oui	Non	Oui	Non
Abonnements	Oui	Oui	Non	Oui	
Articles d'abonnement	Non	Oui	Non	Oui	Non
Horaires d'abonnement	Oui	Oui	Non	Oui	Oui
Comptes	Non	Oui	Non	Oui	Oui
Frais de dossier	Oui	Oui	Non	Oui	Oui

Entité	Peut être filtré	Limite de supports	Supporte Order By	Supporte Select *	Supporte le partitionnement
Spécifications du pays	Non	Oui	Non	Oui	Non
Transferts	Oui	Oui	Non	Oui	Oui
Avertissements précoces en matière de fraude	Oui	Oui	Non	Oui	Oui
Types de rapport	Non	Non	Non	Oui	Non

Exemple

```
stripe_read = glueContext.create_dynamic_frame.from_options(
    connection_type="stripe",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "coupons",
        "API_VERSION": "v1"
    }
)
```

Détails de l'entité et du champ Stripe

Entité	Champ	Type de données	Opérateurs pris en charge
Équilibre			
	available	Liste	
	connect_réservé	Liste	

Entité	Champ	Type de données	Opérateurs pris en charge
	en suspens	Liste	
	mode en direct	Booléen	
	objet	Chaîne	
	instantanément disponible	Liste	
	délivrant	Struct	
Transactions de solde			
	id	Chaîne	
	objet	Chaîne	
	amount	Entier	
	disponible_le	DateTime	=, >=, <=, <, >
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	
	description	Chaîne	
	taux de change	BigDecimal	
	frais	Entier	
	détails des frais	Liste	
	net	Entier	
	catégorie_de reporting	Chaîne	
	source	Chaîne	=

Entité	Champ	Type de données	Opérateurs pris en charge
	status	Chaîne	
	type	Chaîne	=
	classification transfrontalière	Chaîne	
Frais			
	id	Chaîne	
	objet	Chaîne	
	amount	Entier	=, <, >
	montant_capturé	Entier	
	montant_remboursé	Entier	
	application	Chaîne	
	frais de candidature	Chaîne	
	montant des frais de candidature	Entier	
	solde_transaction	Chaîne	
	détails de facturation	Struct	
	descripteur_de_déclaration calculé	Chaîne	
	capturé	Booléen	
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	customer	Chaîne	=
	description	Chaîne	
	destination	Chaîne	
	contentieux	Chaîne	
	contesté	Booléen	=
	failure_balance_transaction	Chaîne	
	code_d'échec	Chaîne	
	message_d'échec	Chaîne	
	détails de la fraude	Struct	
	facture	Chaîne	
	mode en direct	Booléen	
	métadonnées	Struct	
	au nom de	Chaîne	
	order	Chaîne	
	résultat	Struct	
	payé	Booléen	
	intention de paiement	Chaîne	=
	modèle_paiement	Chaîne	
	détails du mode de paiement	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
	email_reçu	Chaîne	
	numéro_reçu	Chaîne	
	url_reçu	Chaîne	
	remboursé	Booléen	=
	remboursements	Struct	
	examen	Chaîne	
	livraison	Struct	
	source	Struct	
	transfert de source	Chaîne	
	descripteur_declar ation	Chaîne	
	suffixe du descripteur de déclaration	Chaîne	
	status	Chaîne	
	transfert	Chaîne	
	données_de_transfert	Struct	
	groupe_de transfert	Chaîne	=
Litiges			
	id	Chaîne	
	objet	Chaîne	
	amount	Entier	=, <, >

Entité	Champ	Type de données	Opérateurs pris en charge
	solde_transaction	Chaîne	
	transactions de solde	Liste	
	charge	Chaîne	=
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	
	preuve	Struct	
	détails des preuves	Struct	
	est_charge_rembour sable	Booléen	
	mode en direct	Booléen	
	métadonnées	Struct	
	intention de paiement	Chaîne	=
	raison	Chaîne	=
	status	Chaîne	
	détails du mode de paiement	Struct	
Liens vers des fichiers			
	id	Chaîne	
	objet	Chaîne	
	créé	DateTime	=, >=, <=, <, >
	expiré	Booléen	=

Entité	Champ	Type de données	Opérateurs pris en charge
	expires_at	DateTime	
	dans le fichier	Chaîne	=
	mode en direct	Booléen	
	métadonnées	Struct	
	url	Chaîne	
PaymentIntents			
	id	Chaîne	
	objet	Chaîne	
	amount	Entier	
	montant_capturable	Entier	
	détail_montant	Struct	
	montant_reçu	Entier	
	application	Chaîne	
	montant des frais de candidature	Entier	
	modes_de_paiement_automatiques	Struct	
	annulé_at	DateTime	
	motif_de l'annulation	Chaîne	
	méthode_capture	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	client_secret	Chaîne	
	méthode_de confirmation	Chaîne	
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	
	customer	Chaîne	=
	description	Chaîne	
	facture	Chaîne	
	dernier_erreur de paiement	Struct	
	dernière_charge	Chaîne	
	mode en direct	Booléen	
	métadonnées	Struct	
	action_suivante	Struct	
	au nom de	Chaîne	
	modèle_paiement	Chaîne	
	options de méthode de paiement	Struct	
	types de méthodes de paiement	Liste	

Entité	Champ	Type de données	Opérateurs pris en charge
	détails de configuration de la méthode de paiement	Struct	
	traitement	Struct	
	email_reçu	Chaîne	
	examen	Chaîne	
	configuration_utilisation_future	Chaîne	
	livraison	Struct	
	source	Chaîne	
	descripteur_déclaration	Chaîne	
	suffixe du descripteur de déclaration	Chaîne	
	status	Chaîne	
	données_de_transfert	Struct	
	groupe_de transfert	Chaîne	
SetupIntents			
	id	Chaîne	
	objet	Chaîne	
	application	Chaîne	
	motif_de l'annulation	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	client_secret	Chaîne	
	créé	DateTime	=, >=, <=, <, >
	customer	Chaîne	=
	description	Chaîne	
	direction_de_flux	Liste	
	dernière_erreur_in stallation	Struct	
	dernière_tentative	Chaîne	
	mode en direct	Booléen	
	mandat	Chaîne	
	métadonnées	Struct	
	action_suivante	Struct	
	au nom de	Chaîne	
	modèle_paiement	Chaîne	
	options de méthode de paiement	Struct	
	types de méthodes de paiement	Liste	
	Mandat à usage unique	Chaîne	
	status	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	utilisation	Chaîne	
	modes_de_ payement_automatiq ues	Struct	
Versements			
	id	Chaîne	
	objet	Chaîne	
	amount	Entier	=, <, >
	date_d'arrivée	DateTime	=, >=, <=, <, >
	automatique	Booléen	
	solde_transaction	Chaîne	
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	
	description	Chaîne	=
	destination	Chaîne	
	failure_balance_tr ansaction	Chaîne	
	code_d'échec	Chaîne	
	message_d'échec	Chaîne	
	mode en direct	Booléen	
	métadonnées	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
	méthode	Chaîne	
	payement_original	Chaîne	
	inversed_by	Chaîne	
	état_de la réconciliation	Chaîne	
	source_type	Chaîne	
	descripteur_déclaration	Chaîne	
	status	Chaîne	
	type	Chaîne	
	frais de candidature	Chaîne	
	montant des frais de candidature	Entier	
Remboursements			
	id	Chaîne	
	objet	Chaîne	
	amount	Entier	
	solde_transaction	Chaîne	
	charge	Chaîne	=
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	métadonnées	Struct	
	détails de la destination	Struct	
	intention de paiement	Chaîne	=
	raison	Chaîne	
	numéro_reçu	Chaîne	
	renversement du transfert de source	Chaîne	
	status	Chaîne	
	transfer_reversal	Chaîne	
Produits			
	id	Chaîne	
	objet	Chaîne	
	actif	Booléen	=
	attributs	Liste	
	créé	DateTime	=, >=, <=, <, >
	prix_par défaut	Chaîne	
	description	Chaîne	
	images	Liste	
	mode en direct	Booléen	
	métadonnées	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
	name	Chaîne	
	dimensions du colis	Struct	
	expédiable	Booléen	
	descripteur_déclaration	Chaîne	
	code_taxe	Chaîne	
	type	Chaîne	=
	étiquette de l'unité	Chaîne	
	updated	DateTime	
	url	Chaîne	
	fonctionnalités	Liste	
Les prix			
	id	Chaîne	
	objet	Chaîne	
	actif	Booléen	=
	schéma de facturation	Chaîne	
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	=
	montant_unité_personnalisé	Struct	
	mode en direct	Booléen	

Entité	Champ	Type de données	Opérateurs pris en charge
	clé_de recherche	Chaîne	
	métadonnées	Struct	
	nickname	Chaîne	
	produit	Chaîne	=
	récurrent	Struct	
	comportement_fiscal	Chaîne	
	tiers_mode	Chaîne	
	transform_quantité	Struct	
	type	Chaîne	=
	montant_unité	Entier	
	unit_montant_décimal	Chaîne	
Coupons			
	Id	Chaîne	
	objet	Chaîne	
	montant_off	Entier	
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	=
	duration	Chaîne	=
	durée en mois	Entier	=, <, >
	mode en direct	Booléen	

Entité	Champ	Type de données	Opérateurs pris en charge
	max_redemptions	Entier	=, <, >
	métadonnées	Struct	
	name	Chaîne	
	pourcentage de réduction	Double	=
	redeem_by	DateTime	=, >=, <=, <, >
	fois échangés	Entier	
	valid	Booléen	
Codes promotionnels			
	Id	Chaîne	
	objet	Chaîne	
	actif	Booléen	=
	code	Chaîne	=
	coupon	Struct	
	créé	DateTime	=,>=,<=,<,>
	customer	Chaîne	
	expires_at	DateTime	
	mode en direct	Booléen	
	max_redemptions	Entier	
	métadonnées	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
	restrictions	Struct	
	fois échangés	Entier	
Codes fiscaux			
	Id	Chaîne	
	objet	Chaîne	
	description	Chaîne	
	name	Chaîne	
Taux d'imposition			
	Id	Chaîne	
	objet	Chaîne	
	actif	Booléen	=
	country	Chaîne	
	créé	DateTime	=, >=, <=, <, >
	description	Chaîne	
	display_name	Chaîne	
	compris	Booléen	=
	juridiction	Chaîne	
	jurisdiction_level	Chaîne	
	mode en direct	Booléen	
	métadonnées	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
	percentage	Double	
	pourcent_effectif	Double	
	state	Chaîne	
	type_taxe	Chaîne	
Tarifs d'expédition			
	Id	Chaîne	
	objet	Chaîne	
	actif	Booléen	=
	créé	DateTime	=, >=, <=, <, >
	estimation_de livraison	Struct	
	display_name	Chaîne	
	montant_fixe	Struct	
	mode en direct	Booléen	
	métadonnées	Struct	
	comportement_fiscal	Chaîne	
	code_taxe	Chaîne	
	type	Chaîne	
Séances			
	id	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	objet	Chaîne	
	après_expiration	Struct	
	autoriser_codes promotionnels	Booléen	
	montant_sous-total	Entier	
	montant_total	Entier	
	taxe_automatique	Struct	
	collecte d'adresses de facturation	Chaîne	
	annuler_url	Chaîne	
	identifiant_référence_client	Chaîne	
	consentement	Struct	
	recueil de consentements	Struct	
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	
	texte_personnalisé	Struct	
	customer	Chaîne	
	création_client	Chaîne	
	Informations sur le client	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
	courriel_client	Chaîne	
	expires_at	DateTime	
	facture	Chaîne	
	création_facture	Struct	
	mode en direct	Booléen	
	locale	Chaîne	
	métadonnées	Struct	
	mode	Chaîne	
	intention de paiement	Chaîne	=
	lien_paiement	Chaîne	
	modèle_paiement	Chaîne	
	options de méthode de paiement	Struct	
	types de méthodes de paiement	Liste	
	état_du paiement	Chaîne	
	collection de numéros de téléphone	Struct	
	recupéré_depuis	Chaîne	
	setup_intent	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	adresse_d'expédition_collecte	Struct	
	coût_d'expédition	Struct	
	détails d'expédition	Struct	
	options d'expédition	Liste	
	status	Chaîne	
	type_d'envoi	Chaîne	
	abonnement	Chaîne	
	urle_succès	Chaîne	
	collection d'identifiants fiscaux	Struct	
	total_détails	Struct	
	url	Chaîne	
	ui_mode	Chaîne	
Notes de crédit			
	id	Chaîne	
	objet	Chaîne	
	amount	Entier	
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	
	customer	Chaîne	=

Entité	Champ	Type de données	Opérateurs pris en charge
	transaction du solde du client	Chaîne	
	montant_de la réduction	Entier	
	montant_escomptes	Liste	
	facture	Chaîne	=
	lines	Struct	
	mode en direct	Booléen	
	note	Chaîne	
	métadonnées	Struct	
	nombre	Chaîne	
	montant hors bande	Entier	
	pdf	Chaîne	
	raison	Chaîne	
	remboursement	Chaîne	
	status	Chaîne	
	sous-total	Entier	
	sous-total_exclu_taxe	Entier	
	montants_taxes	Liste	
	total	Entier	
	total_exclu_taxe	Entier	

Entité	Champ	Type de données	Opérateurs pris en charge
	type	Chaîne	
	voided_at	DateTime	
	montant_expédition	Entier	
	effective_at	DateTime	
	coût_d'expédition	Struct	
Client			
	id	Chaîne	
	objet	Chaîne	
	adresse	Struct	
	balance	Entier	
	créé	DateTime	
	devise	Chaîne	=, >=, <=, <, >
	source_par défaut	Chaîne	
	délinquant	Booléen	=
	description	Chaîne	
	discount	Struct	
	e-mail	Chaîne	=
	préfixe_facture	Chaîne	
	paramètres_facture	Struct	
	mode en direct	Booléen	

Entité	Champ	Type de données	Opérateurs pris en charge
	métadonnées	Struct	
	name	Chaîne	
	séquence_facture suivante	Entier	
	phone	Chaîne	
	locales_préférées	Liste	
	livraison	Struct	
	tax_exempt	Chaîne	
	horloge_test	Chaîne	
Factures			
	id	Chaîne	
	objet	Chaîne	
	pays/compte	Chaîne	
	account_name	Chaîne	
	account_tax_ids	Liste	
	montant_dû	Entier	
	montant_payé	Entier	
	montant_restant	Entier	
	application	Chaîne	
	montant des frais de candidature	Entier	

Entité	Champ	Type de données	Opérateurs pris en charge
	nombre de tentatives	Entier	
	tenté	Booléen	=
	auto_advance	Booléen	=
	taxe_automatique	Struct	
	Motif de facturation	Chaîne	
	charge	Chaîne	
	méthode_collecte	Chaîne	=
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	
	custom_fields	Liste	
	customer	Chaîne	=
	customer_address	Struct	
	courriel_client	Chaîne	
	nom_client	Chaîne	
	téléphone_client	Chaîne	
	expédition par le client	Struct	
	exonéré d'impôts pour le client	Chaîne	
	identifiant_tax_clients	Liste	
	méthode de paiement par défaut	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	source_par défaut	Chaîne	
	taxes_de_default_rates	Liste	
	description	Chaîne	
	discount	Struct	
	remises	Liste	
	due_date	DateTime	=, >=, <=, <, >
	fining_balance	Entier	
	bas de page	Chaîne	
	from_invoice	Struct	
	URL de facture hébergée	Chaîne	
	facture_pdf	Chaîne	
	dernière_erreur de finalisation	Struct	
	dernière_révision	Chaîne	
	lines	Struct	
	mode en direct	Booléen	
	métadonnées	Struct	
	tentative de paiement suivante	DateTime	

Entité	Champ	Type de données	Opérateurs pris en charge
	nombre	Chaîne	
	au nom de	Chaîne	
	payé	Booléen	=
	payd_out_of_band	Booléen	
	intention de paiement	Chaîne	
	paramètres_de paiement	Struct	
	fin de période	DateTime	=, >=, <=, <, >
	period_start	DateTime	=, >=, <=, <, >
	post_payment_credit_notes_amount	Entier	
	montant des notes de crédit avant le paiement	Entier	
	citation	Chaîne	
	numéro_reçu	Chaîne	
	rendu	Struct	
	options de rendu	Struct	
	balance de départ	Entier	
	descripteur_déclaration	Chaîne	
	status	Chaîne	=

Entité	Champ	Type de données	Opérateurs pris en charge
	status_transitions	Struct	
	abonnement	Chaîne	
	détails de l'abonnement	Struct	
	sous-total	Entier	=, <, >
	sous-total_exclu_taxe	Entier	
	taxe	Entier	
	horloge_test	Chaîne	
	total	Entier	=, <, >
	montant_des_escomptes totaux	Liste	
	total_exclu_taxe	Entier	
	montant_taxes_totaux	Liste	
	données_de_transfert	Struct	
	webhooks_delivered_at	DateTime	
	finalise_automatiquement_at	DateTime	
	effective_at	DateTime	
	émetteur	Struct	
Articles de facture			

Entité	Champ	Type de données	Opérateurs pris en charge
	id	Chaîne	
	objet	Chaîne	
	amount	Entier	=, <, >
	devise	Chaîne	
	customer	Chaîne	=
	date	DateTime	
	description	Chaîne	
	à prix réduit	Booléen	
	remises	Liste	
	facture	Chaîne	=
	mode en direct	Booléen	
	métadonnées	Struct	
	point	Struct	
	plan	Struct	
	prix	Struct	
	calcul au prorata	Booléen	=
	quantity	Entier	
	abonnement	Chaîne	
	article_abonnement	Chaîne	
	taxes_taux	Liste	

Entité	Champ	Type de données	Opérateurs pris en charge
	horloge_test	Chaîne	
	montant_unité	Entier	
	unit_montant_décimal	Chaîne	
Plans			
	id	Chaîne	
	objet	Chaîne	
	actif	Booléen	=
	utilisation_agrégée	Chaîne	
	amount	Entier	
	montant_décimal	Chaîne	
	schéma de facturation	Chaîne	
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	=
	interval	Chaîne	=
	comptage des intervalles	Entier	
	mode en direct	Booléen	
	métadonnées	Struct	
	nickname	Chaîne	
	produit	Chaîne	=

Entité	Champ	Type de données	Opérateurs pris en charge
	tiers_mode	Chaîne	
	transform_usage	Struct	
	trial_period_days	Entier	=, <, >
	type_d'utilisation	Chaîne	
	meter	Chaîne	
Citations			
	id	Chaîne	
	objet	Chaîne	
	montant_sous-total	Entier	
	montant_total	Entier	
	application	Chaîne	
	montant des frais de candidature	Entier	
	pourcent_de_frais d'application	Double	
	taxe_automatique	Struct	
	méthode_collecte	Chaîne	
	calculé	Struct	
	créé	DateTime	
	devise	Chaîne	
	customer	Chaîne	=

Entité	Champ	Type de données	Opérateurs pris en charge
	taxes_de_default_rates	Liste	
	description	Chaîne	
	remises	Liste	
	expires_at	DateTime	
	bas de page	Chaîne	
	from_quote	Struct	
	header	Chaîne	
	facture	Chaîne	
	paramètres_facture	Struct	
	mode en direct	Booléen	
	métadonnées	Struct	
	nombre	Chaîne	
	au nom de	Chaîne	
	status	Chaîne	=
	status_transitions	Struct	
	abonnement	Chaîne	
	données_d'abonnement	Struct	
	calendrier_d'abonnement	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	horloge_test	Chaîne	
	total_détails	Struct	
	données_de_transfert	Struct	
Abonnements			
	id	Chaîne	
	objet	Chaîne	
	application	Chaîne	
	pourcent_de_frais d'application	Double	
	taxe_automatique	Struct	
	billing_cycle_anchor	DateTime	
	seuils de facturation	Struct	
	annuler_at	DateTime	
	annuler à la fin de la période	Booléen	
	annulé_at	DateTime	
	méthode_collecte	Chaîne	=
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	
	fin de la période en cours	DateTime	=, >=, <=

Entité	Champ	Type de données	Opérateurs pris en charge
	début de la période en cours	DateTime	=, >=, <=
	customer	Chaîne	=
	jours jusqu'à l'échéance	Entier	
	méthode de paiement par défaut	Chaîne	
	source_par défaut	Chaîne	
	taxes_de_default_rates	Liste	
	description	Chaîne	
	discount	Struct	
	terminé_à	DateTime	
	items	Struct	
	dernière_facture	Chaîne	
	mode en direct	Booléen	
	métadonnées	Struct	
	next_pending_invoice_item_invoice	DateTime	
	pause_collection	Struct	
	paramètres_de paiement	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
	pending_invoice_item_interval	Struct	
	pending_setup_intent	Chaîne	
	mise à jour en attente	Struct	
	plan	Struct	
	quantity	Entier	
	schedule	Chaîne	
	date_de début	DateTime	
	status	Chaîne	=
	horloge_test	Chaîne	
	données_de_transfert	Struct	
	fin d'essai	DateTime	
	début de l'essai	DateTime	
Articles d'abonnement			
	Id	Chaîne	
	objet	Chaîne	
	seuils de facturation	Struct	
	créé	DateTime	=, >=, <=, <, >
	métadonnées	Struct	
	plan	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
	prix	Struct	
	abonnement	Chaîne	
	taxes_taux	Liste	
	remises	Liste	
Horaires d'abonnement			
	objet	Chaîne	
	application	Chaîne	
	annulé_at	DateTime	
	terminé_à	DateTime	
	créé	DateTime	
	phase_actuelle	Struct	
	customer	Chaîne	=
	paramètres_par défaut	Struct	
	comportement_final	Chaîne	
	mode en direct	Booléen	
	métadonnées	Struct	
	phases	Liste	
	released_at	DateTime	
	abonnement_publié	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	intercal_de renouvellement	Chaîne	
	status	Chaîne	
	abonnement	Chaîne	
	horloge_test	Chaîne	
Comptes			
	détails_soumis	Booléen	
	tos_acceptance	Struct	
	type	Chaîne	
	métadonnées	Struct	
	id	Chaîne	
	objet	Chaîne	
	Devise_par défaut	Chaîne	
	caractéristiques	Struct	
	charges_activées	Booléen	
	paramètres	Struct	
	exigences	Struct	
	payouts_activé	Booléen	
	exigences_futures	Struct	
	comptes_externes	Struct	

Entité	Champ	Type de données	Opérateurs pris en charge
	contrôleur	Struct	
	country	Chaîne	
	e-mail	Chaîne	
	créé	DateTime	=, >=, <=, <, >
	profil_entreprise	Struct	
	type_entreprise	Chaîne	
	company	Struct	
Frais de dossier			
	id	Chaîne	
	objet	Chaîne	
	compte	Chaîne	
	amount	Entier	=, <, >
	montant_remboursé	Entier	=, <, >
	application	Chaîne	
	solde_transaction	Chaîne	
	charge	Chaîne	=
	créé	DateTime	
	devise	Chaîne	
	mode en direct	Booléen	
	transaction_origine	Chaîne	

Entité	Champ	Type de données	Opérateurs pris en charge
	remboursé	Booléen	=
	remboursements	Struct	
	source de frais	Struct	
Spécifications du pays			
	id	Chaîne	
	objet	Chaîne	
	Devise_par défaut	Chaîne	
	monnaies_compte_bancaire prises en charge	Struct	
	Devises de paiement prises en charge	Liste	
	méthodes_de paiement pris en charge	Liste	
	pays_de_transfert pris en charge	Liste	
	champs de vérification	Struct	
Transferts			
	id	Chaîne	
	objet	Chaîne	
	amount	Entier	=, <, >

Entité	Champ	Type de données	Opérateurs pris en charge
	montant_inversé	Entier	
	solde_transaction	Chaîne	
	créé	DateTime	=, >=, <=, <, >
	devise	Chaîne	=
	description	Chaîne	
	destination	Chaîne	=
	destination_paiement	Chaîne	
	mode en direct	Booléen	
	métadonnées	Struct	
	renversements	Struct	
	inversé	Booléen	
	transaction_source	Chaîne	
	source_type	Chaîne	
	groupe_de transfert	Chaîne	=
Avertissements précoces en matière de fraude			
	id	Chaîne	
	objet	Chaîne	
	exploitable	Booléen	
	charge	Chaîne	=

Entité	Champ	Type de données	Opérateurs pris en charge
	créé	DateTime	=, >=, <=, <, >
	type de fraude	Chaîne	
	mode en direct	Booléen	
	intention de paiement	Chaîne	=
Types de rapport			
	id	Chaîne	
	objet	Chaîne	
	fin de données_d isponible_	DateTime	
	data_available_start	DateTime	
	colonnes_par défaut	Liste	
	mode en direct	Booléen	
	name	Chaîne	
	updated	DateTime	
	version	Entier	

Requêtes de partitionnement

Des options Spark supplémentaires `PARTITION_FIELD_LOWER_BOUND`, `UPPER_BOUND`, `NUM_PARTITIONS` peuvent être fournies si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.

- LOWER_BOUND: une valeur inférieure inclusive du champ de partition choisi.

Pour la date, nous acceptons le format de date Spark utilisé dans les requêtes SQL Spark.
Exemple de valeur valide : "2024-07-01T00:00:00.000Z".

- UPPER_BOUND: une valeur limite supérieure exclusive du champ de partition choisi.
- NUM_PARTITIONS: nombre de partitions.

Les détails du support des champs de partitionnement par entité sont présentés dans le tableau ci-dessous.

Nom de l'entité	Champ de partitionnement	Type de données
Transactions de solde	créé	DateTime
Frais	créé	DateTime
Litiges	créé	DateTime
Liens vers des fichiers	créé	DateTime
PaymentIntents	créé	DateTime
SetupIntents	créé	DateTime
Versements	créé	DateTime
Remboursements	créé	DateTime
Produits	créé	DateTime
Les prix	créé	DateTime
Coupons	créé	DateTime
Codes promotionnels	créé	DateTime
Taux d'imposition	créé	DateTime
Tarifs d'expédition	créé	DateTime

Nom de l'entité	Champ de partitionnement	Type de données
Séances	créé	DateTime
Notes de crédit	créé	DateTime
Client	créé	DateTime
Factures	créé	DateTime
Plans	créé	DateTime
Abonnements	créé	DateTime
Horaires d'abonnement	créé	DateTime
Comptes	créé	DateTime
Frais de dossier	créé	DateTime
Transferts	créé	DateTime
Avertissements précoces en matière de fraude	créé	DateTime

Exemple

```
stripe_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="stripe",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "coupons",  
        "API_VERSION": "v1",  
        "PARTITION_FIELD": "created"  
        "LOWER_BOUND": "2024-05-01T20:55:02.000Z"  
        "UPPER_BOUND": "2024-07-11T20:55:02.000Z"  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Options de connexion Stripe

Les options de connexion pour Stripe sont les suivantes :

- `ENTITY_NAME`(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Le nom de votre objet dans Stripe.
- `API_VERSION`(Chaîne) - (Obligatoire) Utilisé pour la lecture/écriture. Version de l'API Stripe Rest que vous souhaitez utiliser. Exemple : v1.
- `SELECTED_FIELDS`(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- `FILTER_PREDICATE`(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- `QUERY`(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- `PARTITION_FIELD`(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- `UPPER_BOUND`(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Limites

Les limites du connecteur Stripe sont les suivantes :

- Seul le partitionnement basé sur le champ est pris en charge par le connecteur.
- Le partitionnement basé sur les enregistrements n'est pas pris en charge par le connecteur, aucune disposition ne permet de récupérer le nombre total d'enregistrements.
- Le type de données de clé primaire étant String, le partitionnement basé sur l'identifiant n'est pas pris en charge par connecteur.

Création d'un nouveau compte Stripe et configuration de l'application cliente

Création d'un compte Stripe

1. Choisissez sur le lien <https://dashboard.stripe.com/enregistrement>.
2. Entrez votre e-mail, votre nom complet, votre mot de passe et choisissez Créer un compte.
3. Après vous être connecté avec le compte, vérifiez le compte en choisissant Ouvrir Gmail.
4. Vérifiez le compte en cliquant sur le lien de vérification reçu par e-mail.
5. Après avoir cliqué sur vérifier l'adresse e-mail, elle sera redirigée vers une autre page
6. Après avoir cliqué sur Activer les paiements pour activer le compte, il sera redirigé vers la page Activer les paiements (<https://dashboard.stripe.com/bienvenue>). Assurez-vous de renseigner toutes vos informations valides, puis de choisir le bouton Continuer.

Création d'une application Slack pour développeurs

1. Connectez-vous à [Stripe](#).
2. Choisissez Développeurs comme indiqué à l'extrême haut de l'image ci-dessous.
3. Choisissez les clés d'API sous Développeurs.
4. Choisissez Reveal test key pour obtenir les clés d'API.

Connexion à Teradata Vantage dans AWS Glue Studio

AWS Glue fournit un support intégré pour Teradata Vantage. AWS Glue Studio fournit une interface visuelle pour se connecter à Teradata, créer des tâches d'intégration de données et les exécuter sur AWS Glue Studio environnement d'exécution Spark sans serveur.

AWS Glue Studio crée une connexion unifiée pour Teradata Vantage. Pour de plus amples informations, veuillez consulter [Considérations](#).

Rubriques

- [Création d'une connexion Teradata Vantage](#)
- [Création d'un nœud source Teradata](#)
- [Création d'un nœud cible Teradata](#)
- [Options avancées](#)

Création d'une connexion Teradata Vantage

Pour vous connecter à Teradata Vantage depuis AWS Glue, vous devez créer et stocker vos informations d'identification Teradata dans un AWS Secrets Manager secret, puis associer ce secret à une AWS Glue connexion Teradata.

Prérequis :

- Si vous accédez à votre environnement Teradata via Amazon VPC, configurez Amazon VPC pour permettre à AWS Glue votre tâche de communiquer avec l'environnement Teradata. Nous vous déconseillons d'accéder à l'environnement Teradata via l'Internet public.

Dans Amazon VPC, identifiez ou créez un VPC, un sous-réseau et un groupe de sécurité qui AWS Glue seront utilisés lors de l'exécution de la tâche. En outre, vous devez vous assurer qu'Amazon VPC est configuré pour autoriser le trafic réseau entre votre instance Teradata et cet emplacement. Votre tâche devra établir une connexion TCP avec votre port client Teradata. Pour de plus amples informations sur les ports Teradata, consultez la [documentation Teradata](#).

Selon la configuration de votre réseau, la connectivité VPC sécurisée peut nécessiter des modifications dans Amazon VPC et dans d'autres services réseau. Pour plus d'informations sur AWS la connectivité, consultez [les options de AWS connectivité](#) dans la documentation Teradata.

Pour configurer une connexion AWS Glue Teradata :

1. Dans votre configuration Teradata, identifiez ou créez un utilisateur et un mot de passe AWS Glue vous permettra de vous connecter à, *teradataUser* et *teradataPassword*. Pour plus d'informations, consultez la [présentation de Vantage Security](#) dans la documentation Teradata.
2. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification Teradata. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé user contenant la valeur. *teradataUsername*
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé password contenant la valeur. *teradataPassword*

3. Dans la AWS Glue console, créez une connexion en suivant les étapes décrites dans [the section called “Ajouter une AWS Glue connexion”](#). Après avoir créé la connexion, conservez le nom de la connexion pour l'étape suivante. *connectionName*
 - Lorsque vous sélectionnez un type de connexion, sélectionnez Teradata.
 - Lorsque vous fournissez l'URL JDBC, indiquez l'URL de votre instance. Vous pouvez également coder en dur certains paramètres de connexion séparés par des virgules dans votre URL JDBC. L'URL doit être conforme au format suivant :
`jdbc:teradata://teradataHostname/ParameterName=ParameterValue,ParameterName`

Les paramètres d'URL pris en charge sont les suivants :

 - DATABASE – nom de la base de données sur l'hôte à laquelle accéder par défaut.
 - DBS_PORT – le port de base de données utilisé lors de l'exécution sur un port non standard.
 - Lorsque vous sélectionnez un type d'identifiant, sélectionnez AWS Secrets Manager, puis définissez AWS Secret sur *secretName*.
4. Dans les situations suivantes, vous pouvez avoir besoin d'une configuration supplémentaire :
 - Pour les instances Teradata hébergées sur AWS un Amazon VPC
 - Vous devrez fournir les informations de connexion Amazon VPC à la AWS Glue connexion qui définit vos informations d'identification de sécurité Teradata. Lorsque vous créez ou mettez à jour votre connexion, définissez le VPC, le sous-réseau et les groupes de sécurité dans les options réseau.

Création d'un nœud source Teradata

Prérequis

- Une connexion AWS Glue Teradata Vantage, configurée avec un AWS Secrets Manager secret, comme décrit dans la section précédente, [the section called “Création d'une connexion Teradata Vantage”](#)
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.
- Une table Teradata que vous souhaitez lire ou interroger *targetQuery*. *tableName*

Ajout d'une source de données Teradata

Pour ajouter un nœud Source de données – Teradata :

1. Choisissez la connexion pour votre source de données Teradata. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Créer une nouvelle connexion. Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion Teradata Vantage”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Choisissez une option Source Teradata :
 - Choisissez une seule table : accéder à toutes les données à partir d'une seule table.
 - Saisir une requête personnalisée : accéder à un jeu de données à partir de plusieurs tables en fonction de votre requête personnalisée.
3. Si vous avez choisi une seule table, entrez *tableName*.

Si vous avez choisi Saisir une requête personnalisée, saisissez une requête SQL SELECT.

4. Dans les Propriétés Teradata personnalisées, saisissez les paramètres et les valeurs nécessaires.

Création d'un nœud cible Teradata

Prérequis

- Une connexion AWS Glue Teradata Vantage, configurée avec un AWS Secrets Manager secret, comme décrit dans la section précédente, [the section called “Création d'une connexion Teradata Vantage”](#)
- Les autorisations appropriées sur votre tâche pour lire le secret utilisé par la connexion.
- Une table Teradata dans laquelle vous souhaitez écrire, *tableName*.

Ajout d'une cible de données Teradata

Pour ajouter un nœud Cible de données – Teradata :

1. Choisissez la connexion pour votre source de données Teradata. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez

Créer une connexion Teradata. Pour en savoir plus, consultez [Overview of using connectors and connections](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Configurez le nom de la table en fournissant *tableName*.
3. Dans les Propriétés Teradata personnalisées, saisissez les paramètres et les valeurs nécessaires.

Options avancées

Vous pouvez fournir des options avancées lors de la création d'un nœud Teradata. Ces options sont les mêmes que celles disponibles lors de la programmation AWS Glue de scripts Spark.

Consultez [the section called “Connexions Teradata Vantage”](#).

Connexion à Twilio

Twilio fournit des outils de communication programmables pour passer et recevoir des appels téléphoniques, envoyer et recevoir des messages texte, et exécuter d'autres fonctions de communication à l'aide de son service APIs Web. Twilio APIs alimente sa plateforme de communication. Derrière cela se APIs trouve une couche logicielle qui connecte et optimise les réseaux de communication du monde entier pour permettre à vos utilisateurs d'appeler et d'envoyer des messages à n'importe qui, dans le monde entier. En tant qu'utilisateur de Twilio, vous pouvez vous connecter AWS Glue à votre compte Twilio. Ensuite, vous pouvez utiliser Twilio comme source de données dans vos tâches ETL. Exécutez ces jobs pour transférer des données entre Twilio et AWS des services ou d'autres applications prises en charge.

Rubriques

- [AWS Glue support pour Twilio](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Twilio](#)
- [Configuration des connexions Twilio](#)
- [Lecture à partir d'entités Twilio](#)
- [Options de connexion Twilio](#)

- [Limitations et remarques relatives au connecteur Twilio](#)

AWS Glue support pour Twilio

AWS Glue soutient Twilio comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Twilio.

Soutenu en tant que cible ?

Non

Versions de l'API Twilio prises en charge

Les versions suivantes de l'API Twilio sont prises en charge :

- v1
- 2010-04-01

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

```
]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Twilio

Avant de pouvoir AWS Glue transférer des données depuis Twilio, vous devez répondre aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un compte Twilio avec nom d'utilisateur et mot de passe.
- Votre compte Twilio est activé pour accéder à l'API.

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre compte Twilio. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Twilio.

Configuration des connexions Twilio

Twilio prend en charge le nom d'utilisateur et le mot de passe pour l'authentification de base. L'authentification de base est une méthode d'authentification simple dans laquelle les clients fournissent des informations d'identification directement pour accéder aux ressources protégées.

AWS Glue est capable d'utiliser le nom d'utilisateur (SID du compte) et le mot de passe (jeton d'authentification) pour authentifier Twilio. APIs

Pour consulter la documentation publique de Twilio sur le flux d'authentification de base, voir [Authentification de base | Twilio](#).

Pour configurer une connexion Twilio :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :

- Pour l'authentification de base : le secret doit contenir le secret du consommateur de l'application connectée avec le SID du compte (nom d'utilisateur) et le jeton d'authentification (mot de passe).

 Note

Vous devez créer un secret pour vos connexions dans AWS Glue.

2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :

- a. Lorsque vous sélectionnez un type de connexion, sélectionnez Twilio.
- b. Indiquez l'instance [Edge_Location](#) de Twilio à laquelle vous souhaitez vous connecter.
- c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

}

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture à partir d'entités Twilio

Prérequis

Un objet Twilio dont vous aimeriez lire un extrait. Vous aurez besoin du nom de l'objet tel que `SMS-Message` ou `SMS-CountryPricing`.

Entités prises en charge pour la source :

Entité	utilisateur	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Message-SMS	REST	Oui	Oui	Non	Oui	Oui
SMS-CountryPricing	REST	Non	Non	Non	Oui	Non
Appel vocal	REST	Oui	Oui	Non	Oui	Non
Application vocale	REST	Oui	Oui	Non	Oui	Non
OutgoingCallIdentifier	REST	Oui	Oui	Non	Oui	Non

Entité	utilisateur	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
File d'attente vocale	REST	Oui	Oui	Non	Oui	Non
Conversations - Conversations	REST	Oui	Oui	Non	Oui	Non
Conversations - Utilisateur	REST	Non	Oui	Non	Oui	Non
Rôle des conversations	REST	Non	Oui	Non	Oui	Non
Configuration des conversations	REST	Non	Non	Non	Oui	Non
Conversations-AddressConfiguration	REST	Oui	Oui	Non	Oui	Non
Conversations-WebhookConfiguration	REST	Non	Non	Non	Oui	Non

Entité	utilisateur	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Conversations-ParticipantConversation	REST	Non	Non	Non	Oui	Non
Informations d'identification pour les conversations	REST	Non	Oui	Non	Oui	Non
Conversations-ConversationService	REST	Non	Oui	Non	Oui	Non

Exemple :

```
twilio_read = glueContext.create_dynamic_frame.from_options(
    connection_type="twilio",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "sms-message",
        "API_VERSION": "2010-04-01",
        "Edge_Location": "sydney.us1"
    }
)
```

Détails de l'entité et du champ Twilio :

Entité	Champ	Type de données	Opérateurs pris en charge
Message-SMS	ID du compte	Chaîne	N/A
	api_version	Chaîne	N/A
	body	Chaîne	N/A
	date_créée	Datetime	N/A
	date_d'envoi	Datetime	>=, <=, =
	date_mise à jour	Datetime	N/A
	direction	Chaîne	N/A
	error_code	Entier	N/A
	error_message	Chaîne	N/A
	from	Entier	=
	messaging_service_sid	Chaîne	N/A
	num_media	Chaîne	N/A
	num_segments	Chaîne	N/A
	prix	Chaîne	N/A
	prix_unité	Struct	N/A
	sid	Entier	N/A
	status	Chaîne	N/A
	subresource_uris	Map	N/A
	to	Entier	=

Entité	Champ	Type de données	Opérateurs pris en charge
SMS- CountryPricing	uri	Datetime	N/A
	country	Chaîne	N/A
	iso_country	Chaîne	N/A
	url	Chaîne	N/A
	prix_SMS sortants	Liste	N/A
	prix_des SMS entrants	Liste	N/A
Appel vocal	prix_unité	Chaîne	N/A
	ID du compte	Chaîne	N/A
	annotation	Chaîne	N/A
	répondu_par	Chaîne	N/A
	api_version	Chaîne	N/A
	nom_appelant	Chaîne	N/A
	date_créée	Datetime	N/A
	date_mise à jour	Datetime	N/A
	direction	Chaîne	N/A
	duration	Chaîne	N/A
	end_time	Datetime	>=, <=, =
	transféré_depuis	Chaîne	N/A
	from	Chaîne	=

Entité	Champ	Type de données	Opérateurs pris en charge
	from_formatted	Chaîne	N/A
	group_sid	Chaîne	N/A
	parent_call_sid	Chaîne	N/A
	numéro_de téléphone _sid	Chaîne	N/A
	prix	Chaîne	N/A
	prix_unité	Chaîne	N/A
	sid	Chaîne	N/A
	start_time	Datetime	>=, <=, =
	status	Chaîne	=
	subresource_uris	Chaîne	N/A
	to	Chaîne	=
	to_formaté	Chaîne	N/A
	trunk_sid	Chaîne	N/A
	uri	Chaîne	N/A
	queue_time	Chaîne	N/A
Application vocale	ID du compte	Chaîne	N/A
	api_version	Chaîne	N/A
	date_créée	Datetime	N/A
	date_mise à jour	Datetime	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	nom_convivial	Chaîne	=
	message_status_callback	Chaîne	N/A
	sid	Chaîne	N/A
	méthode sms_fallback_ack_	Chaîne	N/A
	sms_fallback_url	Chaîne	N/A
	méthode sms	Chaîne	N/A
	sms_status_callback	Chaîne	N/A
	url du sms	Chaîne	N/A
	status_callback	Chaîne	N/A
	méthode status_callback_	Chaîne	N/A
	uri	Chaîne	N/A
	recherche de l'identifiant de l'appelant vocal	Booléen	N/A
	méthode voice_fallback_	Chaîne	N/A
	voice_fallback_url	Chaîne	N/A
	méthode_vocale	Chaîne	N/A
	URL_vocale	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
public_application_connect_enabled	Booléen	N/A	
OutgoingCallerIdentification vocale	sid	Chaîne	N/A
	date_créée	Datetime	N/A
	date_mise à jour	Datetime	N/A
	ID du compte	Chaîne	N/A
	nom_convivial	Chaîne	=
	phone_number	Chaîne	=
	uri	Chaîne	N/A
File d'attente vocale	date_créée	Datetime	N/A
	date_mise à jour	Datetime	N/A
	taille_actuelle	Entier	N/A
	nom_convivial	Chaîne	N/A
	uri	Chaîne	N/A
	ID du compte	Chaîne	N/A
	temps d'attente moyen	Entier	N/A
	sid	Chaîne	N/A
	taille_maximale	Entier	N/A
Conversations - Conversations	ID du compte	Chaîne	N/A
	chat_service_sid	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	messaging_service_sid	Chaîne	N/A
	sid	Chaîne	N/A
	nom_convivial	Chaîne	N/A
	nom_unique	Chaîne	N/A
	attributs	Chaîne	N/A
	state	Chaîne	=
	date_créée	Datetime	N/A
	date_mise à jour	Datetime	N/A
	minuteries	Struct	N/A
	url	Chaîne	N/A
	links	Struct	N/A
	fixations	Struct	N/A
	date_de début	Datetime	=
	date de fin	Datetime	=
	Minuteries. DateInactive	Chaîne	N/A
	Minuteries. DateClosed	Chaîne	N/A
Conversations - Utilisateur	sid	Chaîne	N/A
	ID du compte	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	chat_service_sid	Chaîne	N/A
	role_sid	Chaîne	N/A
	une	Chaîne	N/A
	nom_convivial	Chaîne	N/A
	attributs	Chaîne	N/A
	est en ligne	Booléen	N/A
	est notifiable	Booléen	N/A
	date_créée	Datetime	N/A
	date_mise à jour	Datetime	N/A
	url	Chaîne	N/A
	links	Struct	N/A
Rôle des conversations	sid	Chaîne	N/A
	ID du compte	Chaîne	N/A
	chat_service_sid	Chaîne	N/A
	nom_convivial	Chaîne	N/A
	type	Chaîne	N/A
	des autorisations	Chaîne	N/A
	date_créée	Datetime	N/A
	date_mise à jour	Datetime	N/A
	url	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
Configuration des conversations	ID du compte	Long	N/A
	default_chat_service_sid	Chaîne	N/A
	default_messaging_service_sid	Chaîne	N/A
	temporisateur inactif par défaut	Chaîne	N/A
	temporisateur fermé par défaut	Chaîne	N/A
	url	Chaîne	N/A
	links	Map	N/A
Conversations-AddressConfiguration	sid	Chaîne	N/A
	ID du compte	Chaîne	N/A
	type	Chaîne	N/A
	adresse	Chaîne	N/A
	nom_convivial	Chaîne	N/A
	auto_création	Struct	N/A
	date_créée	Datetime	N/A
	date_mise à jour	Datetime	N/A
	url	Chaîne	N/A
	adresse_pays	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	AutoCreation.Activé	Booléen	N/A
	AutoCreation.Type	Chaîne	N/A
	AutoCreation.ConversationServiceSid	Chaîne	N/A
	AutoCreation.WebhookUrl	Chaîne	N/A
	AutoCreation.WebhookMethod	Chaîne	N/A
	AutoCreation.WebhookFilters	Liste	N/A
	AutoCreation.StudioFlowSid	Chaîne	N/A
	AutoCreation.StudioRetryCount	Entier	N/A
Conversations-WebhookConfiguration	ID du compte	Chaîne	N/A
	méthode	Chaîne	N/A
	filtres	Liste	N/A
	pre_webhook_url	Chaîne	N/A
	post_webhook_url	Chaîne	N/A
	cible	Chaîne	N/A
	url	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
Conversations-ParticipantConversation	ID du compte	Chaîne	N/A
	chat_service_sid	Chaîne	N/A
	participant_sid	Chaîne	N/A
	participant_utilisateur_sid	Chaîne	N/A
	identité_participant	Chaîne	N/A
	Participant_messaging_binding	Struct	N/A
	Conversation_SID	Chaîne	N/A
	nom_unique_conversation	Chaîne	N/A
	nom_convivial pour la conversation	Chaîne	N/A
	attributs_de conversation	Chaîne	N/A
	date_conversation_créée	Datetime	N/A
	date_de_conversation_mise à jour	Datetime	N/A
	conversation créée par	Chaîne	N/A
	état_de conversation	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	minuteries de conversation	Struct	N/A
	links	Map	N/A
	adresse	Chaîne	=
	une	Chaîne	=
Identifiants de conversation	sid	Chaîne	N/A
	ID du compte	Chaîne	N/A
	nom_convivial	Chaîne	N/A
	type	Chaîne	N/A
	sandbox	Chaîne	N/A
	date_créée	Datetime	N/A
	daté_mis à jour	Datetime	N/A
	url	Chaîne	N/A
	certificat	Chaîne	N/A
	private_key	Chaîne	N/A
	clé_api	Chaîne	N/A
	secret	Chaîne	N/A
Conversations- ConversationService	sid	Chaîne	N/A
	ID du compte	Chaîne	N/A
	nom_convivial	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	date_créée	Datetime	N/A
	date_mise à jour	Datetime	N/A
	url	Chaîne	N/A
	links	Map	N/A

Requêtes de partitionnement

Champs supportant le partitionnement :

Dans Twilio, les champs de type de DateTime données prennent en charge le partitionnement basé sur les champs.

Vous pouvez fournir les options supplémentaires de Spark

`PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, et `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur inférieure inclusive du champ de partition choisi.

Pour le champ `Datetime`, nous acceptons le format d'horodatage Spark utilisé dans les requêtes SQL Spark.

Exemples de valeurs valides :

```
"2024-05-01T20:55:02.000Z"
```

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`: le nombre de partitions.

Exemple :

```
twilio_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="twilio",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "sms-message",  
        "API_VERSION": "2010-04-01",  
        "PARTITION_FIELD": "date_sent"  
        "LOWER_BOUND": "2024-05-01T20:55:02.000Z"  
        "UPPER_BOUND": "2024-06-01T20:55:02.000Z"  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Options de connexion Twilio

Les options de connexion pour Twilio sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Twilio.
- **EDGE_LOCATION**(String) - (Obligatoire) Un emplacement Twilio Edge valide.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Twilio Rest que vous souhaitez utiliser. Twilio prend en charge deux versions d'API : « v1 » et « 2010-04-01 ».
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions pour Read.
- **INSTANCE_URL**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Une URL d'instance Twilio valide.

Limitations et remarques relatives au connecteur Twilio

Voici les limitations ou remarques relatives au connecteur Twilio :

- Le partitionnement basé sur les enregistrements n'est pas pris en charge, car aucune disposition ne permet de récupérer le nombre total d'enregistrements auprès de Twilio.
- Les champs `date_sentstart_time`, et `end_time` sont du type `Datetime`, mais lors du filtrage, ils ne prennent en charge que les valeurs de date (les composants temporels ne sont pas pris en compte).
- Le filtrage des champs « de » ou « à » ne fonctionne que si les valeurs n'incluent aucun préfixe (par exemple, un protocole ou une étiquette). Si un préfixe est présent, le filtrage du champ correspondant ne fonctionne pas. Par exemple, si vous passez « to » : « whatsapp : +14xxxxxxxxxx » comme filtre, Twilio ne renverra aucune réponse. Vous devez le transmettre sous la forme « à » : « +14xxxxxxxxxx », puis il renverra les enregistrements s'ils existent.
- Le filtre de champ « identité » est obligatoire lorsque vous interrogez `conversation-participant-conversationentité`.

Connexion à Vertica dans AWS Glue Studio

AWS Glue fournit un support intégré pour Vertica. AWS Glue Studio fournit une interface visuelle pour se connecter à Vertica, créer des tâches d'intégration de données et les exécuter sur AWS Glue Studio environnement d'exécution Spark sans serveur.

AWS Glue Studio crée une connexion unifiée pour Vertica. Pour de plus amples informations, veuillez consulter [Considérations](#).

Rubriques

- [Création d'une connexion Vertica](#)
- [Création d'un nœud source Vertica](#)
- [Création d'un nœud cible Vertica](#)
- [Options avancées](#)

Création d'une connexion Vertica

Prérequis :

- Un compartiment ou un dossier Amazon S3 à utiliser pour le stockage temporaire lors de la lecture et de l'écriture dans la base de données, désigné par `tempS3Path`.

 Note

Lorsque vous utilisez Vertica dans les aperçus des données de AWS Glue travail, il est possible que les fichiers temporaires ne soient pas automatiquement supprimés.

`tempS3Path` Pour garantir la suppression des fichiers temporaires, mettez directement fin à la session de prévisualisation des données en choisissant Mettre fin à la session dans le volet Prévisualisation des données.

Si vous ne pouvez pas garantir la fin directe de la session de prévisualisation des données, pensez à configurer le cycle de vie d'Amazon S3 pour supprimer les anciennes données.

Nous recommandons de supprimer les données de plus de 49 heures, sur la base de la durée d'exécution maximale des tâches plus une marge. Pour de plus amples informations sur la configuration du cycle de vie Amazon S3, consultez [Gestion du cycle de vie de votre stockage](#) dans la documentation Amazon S3.

- Une politique IAM avec les autorisations appropriées pour votre chemin Amazon S3 que vous pouvez associer à votre rôle AWS Glue professionnel.
- Si votre instance Vertica se trouve dans un Amazon VPC, configurez Amazon VPC pour permettre à AWS Glue votre tâche de communiquer avec l'instance Vertica sans que le trafic ne transite par l'Internet public.

Dans Amazon VPC, identifiez ou créez un VPC, un sous-réseau et un groupe de sécurité qui AWS Glue seront utilisés lors de l'exécution de la tâche. En outre, vous devez vous assurer qu'Amazon VPC est configuré pour autoriser le trafic réseau entre votre instance Vertica et cet emplacement. Votre tâche devra établir une connexion TCP avec votre port client Vertica (par défaut 5433). Selon la configuration de votre réseau, cela peut nécessiter des modifications des règles du groupe de sécurité, du réseau ACLs, des passerelles NAT et des connexions d'appairage.

Pour configurer une connexion à Vertica :

1. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification Vertica, `verticaUsername` et `verticaPassword`. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret `secretName` pour l'étape suivante.

- Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé `user` contenant la valeur. `verticaUsername`
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé `password` contenant la valeur. `verticaPassword`
2. Dans la AWS Glue console, créez une connexion en suivant les étapes décrites dans [the section called “Ajouter une AWS Glue connexion”](#). Après avoir créé la connexion, conservez le nom de la connexion pour l'étape suivante. `connectionName`
- Lorsque vous sélectionnez un type de connexion, sélectionnez Vertica.
 - Lorsque vous sélectionnez l'hôte Vertica, indiquez le nom d'hôte de votre installation Vertica.
 - Lorsque vous sélectionnez le port Vertica, le port via lequel votre installation Vertica est disponible.
 - Lorsque vous sélectionnez un AWS secret, fournissez `secretName`.
3. Dans les situations suivantes, vous pouvez avoir besoin d'une configuration supplémentaire :
- Pour les instances Vertica hébergées AWS dans un Amazon VPC
 - Fournissez les informations de connexion Amazon VPC à la AWS Glue connexion qui définit vos informations de sécurité Vertica. Lorsque vous créez ou mettez à jour votre connexion, définissez le VPC, le sous-réseau et les groupes de sécurité dans les options réseau.

Vous devez effectuer les étapes suivantes avant d'exécuter votre AWS Glue tâche :

- Accordez le rôle IAM associé à vos autorisations de AWS Glue travail à `tempS3Path`.
- Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Création d'un nœud source Vertica

Prérequis

- Une connexion au catalogue de AWS Glue données de type Vertica `connectionName` et un emplacement Amazon S3 temporaire `tempS3Path`, comme décrit dans la section précédente, [the section called “Création d'une connexion Vertica”](#).
- Une table Vertica que vous souhaitez lire ou interroger `targetQuery. tableName`

Ajout d'une source de données Vertica

Pour ajouter un nœud Source de données – Vertica :

1. Choisissez la connexion pour votre source de données Vertica. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez Créer une connexion Vertica. Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion Vertica”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur Afficher les propriétés.

2. Choisissez la Base de données contenant votre table.
3. Choisissez la zone de transit dans Amazon S3, entrez un URI S3A pour *tempS3Path*.
4. Choisissez la Source Vertica.
 - Choisissez une seule table : accéder à toutes les données à partir d'une seule table.
 - Saisir une requête personnalisée : accéder à un jeu de données à partir de plusieurs tables en fonction de votre requête personnalisée.
5. Si vous avez choisi une seule table, entrez *tableName* et sélectionnez éventuellement un schéma.

Si vous avez choisi Saisir une requête personnalisée, saisissez une requête SQL SELECT et sélectionnez éventuellement un Schéma.

6. Dans les Propriétés Vertica personnalisées, saisissez les paramètres et les valeurs nécessaires.

Création d'un nœud cible Vertica

Prérequis

- Une connexion au catalogue de AWS Glue données de type Vertica *connectionName* et un emplacement Amazon S3 temporaire *tempS3Path*, comme décrit dans la section précédente, [the section called “Création d'une connexion Vertica”](#).

Ajout d'une cible de données Vertica

Pour ajouter un nœud Cible de données – Vertica :

1. Choisissez la connexion pour votre source de données Vertica. Puisque vous l'avez créé, il devrait être disponible dans le menu déroulant. Si vous devez créer une connexion, choisissez [Créer une connexion Vertica](#). Pour de plus amples informations, veuillez consulter la section précédente [the section called “Création d'une connexion Vertica”](#).

Une fois que vous avez choisi une connexion, vous pouvez afficher ses propriétés en cliquant sur **Afficher les propriétés**.

2. Choisissez la Base de données contenant votre table.
3. Choisissez la zone de transit dans Amazon S3, entrez un URI S3A pour *tempS3Path*.
4. Entrez *tableName* et sélectionnez éventuellement un schéma.
5. Dans les Propriétés Vertica personnalisées, saisissez les paramètres et les valeurs nécessaires.

Options avancées

Vous pouvez fournir des options avancées lors de la création d'un nœud Vertica. Ces options sont les mêmes que celles disponibles lors de la programmation AWS Glue de scripts Spark.

Consultez [the section called “Connexions Vertica”](#).

Connexion à WooCommerce

WooCommerce est une solution logicielle flexible open source conçue pour les sites Web WordPress basés sur le Web. Il est couramment utilisé pour créer des boutiques de commerce électronique en ligne. Avec cette solution logicielle, n'importe qui peut transformer son site Web habituel en une boutique en ligne entièrement fonctionnelle.

Rubriques

- [AWS Glue support pour WooCommerce](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration WooCommerce](#)
- [Configuration des WooCommerce connexions](#)
- [Lecture à partir d' WooCommerce entités](#)

- [WooCommerce options de connexion](#)

AWS Glue support pour WooCommerce

AWS Glue prend en charge WooCommerce les éléments suivants :

Supportée en tant que source ?

Oui. Vous pouvez utiliser des tâches AWS Glue ETL pour interroger des données à partir de WooCommerce.

Soutenu en tant que cible ?

Non.

Versions WooCommerce d'API prises en charge

Les versions WooCommerce d'API suivantes sont prises en charge :

- v3

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration WooCommerce

Avant de pouvoir AWS Glue transférer des données depuis WooCommerce, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un WooCommerce compte avec a `consumerKey` et `consumerSecret` a.
- Votre WooCommerce compte dispose d'un accès à l'API avec une licence valide.

Si vous remplissez ces conditions, vous êtes prêt à vous connecter AWS Glue à votre WooCommerce compte. Pour les connexions classiques, vous n'avez rien d'autre à faire dans WooCommerce.

Configuration des WooCommerce connexions

WooCommerce prend en charge l'authentification personnalisée. Pour consulter WooCommerce la documentation publique sur la génération des clés d'API requises pour une autorisation personnalisée, consultez [Authentication — Documentation de l' WooCommerce API REST](#).

Pour configurer une WooCommerce connexion :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - Pour une application connectée gérée par le client, le secret doit contenir le secret du consommateur de l'application connectée avec `consumerKey` et `consumerSecret` sous forme de clés. Remarque : vous devez créer un secret par connexion dans AWS Glue.
1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez WooCommerce.
 - b. Indiquez `INSTANCE_URL` l' WooCommerce instance à laquelle vous souhaitez vous connecter.
 - c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture à partir d' WooCommerce entités

Prérequis

Un WooCommerce objet que vous aimeriez lire. Vous aurez besoin du nom de l'objet tel que le coupon, la commande, le produit, etc.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Bon de réduction	Oui	Oui	Oui	Oui	Oui
Total du coupon	Non	Non	Non	Oui	Non
Nombre total de clients	Non	Non	Non	Oui	Non
Ordre	Oui	Oui	Oui	Oui	Oui
Total des commandes	Non	Non	Non	Oui	Non
Passerelle de paiement	Non	Non	Non	Oui	Non
Produit (langue française non garantie)	Oui	Oui	Oui	Oui	Oui
Attribut du produit	Oui	Oui	Oui	Oui	Oui
Catégorie de produit	Oui	Oui	Oui	Oui	Oui
Évaluation du produit	Oui	Oui	Oui	Oui	Oui

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Classe d'expédition du produit	Oui	Oui	Oui	Oui	Oui
Tag du produit	Oui	Oui	Oui	Oui	Oui
Variation du produit	Oui	Oui	Oui	Oui	Oui
Total des produits	Non	Non	Non	Oui	Non
Rapport (liste)	Non	Non	Non	Oui	Non
Nombre total d'avis	Non	Non	Non	Oui	Non
Rapport des ventes	Oui	Non	Non	Oui	Non
Mode d'expédition	Non	Non	Non	Oui	Non
Zone d'expédition	Non	Non	Non	Oui	Non
Emplacement de la zone d'expédition	Non	Non	Non	Oui	Non
Méthode de zone d'expédition	Non	Non	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Taux d'imposition	Oui	Oui	Oui	Oui	Oui
Classe fiscale	Non	Non	Non	Oui	Non
Rapport sur les meilleures ventes	Oui	Non	Non	Oui	Non

Exemple :

```

woocommerce_read = glueContext.create_dynamic_frame.from_options(
    connection_type="glue.spark.woocommerce",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "coupon",
        "API_VERSION": "v3",
        "INSTANCE_URL": "instanceUrl"
    }
  )

```

WooCommerce détails de l'entité et du champ :

Entité	Champ	Type de données	Opérateurs pris en charge
coupon	id	Entier	N/A
	code	Chaîne	EQUAL_TO
	amount	Chaîne	N/A
	status	Chaîne	N/A
	date_créée	DateTime	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	date de création_gmt	DateTime	N/A
	date_modifiée	DateTime	N/A
	date_modifié_gmt	DateTime	N/A
	type_de réduction	Chaîne	N/A
	description	Chaîne	N/A
	date_expire	Chaîne	N/A
	date_expiration_gmt	Chaîne	N/A
	compte_d'utilisation	Entier	N/A
	utilisation_individuelle	Booléen	N/A
	identifiant_produits	Liste	N/A
	identifiant_de_produit exclus	Liste	N/A
	usage_limit	Entier	N/A
	Limite_d'utilisation par utilisateur	Entier	N/A
	limiter_utilisation_à_x_articles	Entier	N/A
	livraison gratuite	Booléen	N/A
	catégories_produits	Liste	N/A
	catégories_de_produits exclus	Liste	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	exclure les articles en vente	Booléen	N/A
	montant_minimum	Chaîne	N/A
	montant_maximum	Chaîne	N/A
	Restrictions relatives aux e-mails	Liste	N/A
	utilisé_par	Liste	N/A
	méta-données	Liste	N/A
	context	Chaîne	EQUAL_TO
	search	Chaîne	EQUAL_TO
	après	DateTime	EQUAL_TO
	avant	DateTime	EQUAL_TO
	order	Chaîne	EQUAL_TO
	commander par	Chaîne	EQUAL_TO
	modifié_après	DateTime	EQUAL_TO
	modifié_avant	DateTime	EQUAL_TO
	les dates sont GMT	Booléen	EQUAL_TO
total du coupon	limace	Chaîne	N/A
	name	Chaîne	N/A
	total	Entier	N/A
total des clients	limace	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	name	Chaîne	N/A
	total	Entier	N/A
order	id	Entier	N/A
	identifiant_parent	Entier	N/A
	nombre	Chaîne	N/A
	clé_commande	Chaîne	N/A
	créé_via	Chaîne	N/A
	status	Chaîne	N/A
	devise	Chaîne	N/A
	version	Chaîne	N/A
	date_créée	DateTime	N/A
	date_modifiée	DateTime	N/A
	total de la réduction	Chaîne	N/A
	impôt_d'escompte	Chaîne	N/A
	total des frais d'expédition	Chaîne	N/A
	taxe_d'expédition	Chaîne	N/A
	cart_tax	Chaîne	N/A
	total	Chaîne	N/A
	impôt_total	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	les prix incluent les taxes	Booléen	N/A
	customer_id	Entier	N/A
	adresse_IP du client	Chaîne	N/A
	agent-utilisateur_client	Chaîne	N/A
	note du client	Chaîne	N/A
	facturation	Struct	N/A
	livraison	Struct	N/A
	modèle_paiement	Chaîne	N/A
	titre_de_méthode de paiement	Chaîne	N/A
	transaction_id	Chaîne	N/A
	date de paiement	DateTime	N/A
	date_terminée	DateTime	N/A
	cart_hash	Chaîne	N/A
	méta-données	Liste	N/A
	articles de ligne	Liste	N/A
	tax_lines	Liste	N/A
	Shipping_lines	Liste	N/A
	lignes tarifaires	Liste	N/A
	coupon_lines	Liste	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	remboursements	Liste	N/A
	URL_de paiement	Chaîne	N/A
	est modifiable	Booléen	N/A
	besoins_paiement	Booléen	N/A
	traitement des besoins	Booléen	N/A
	date de création_gmt	DateTime	N/A
	date_modifié_gmt	DateTime	N/A
	date_terminé_GMT	DateTime	N/A
	date_paid_gmt	DateTime	N/A
	symbole_devis	Chaîne	N/A
	set_paid	Booléen	N/A
	context	Chaîne	EQUAL_TO
	search	Chaîne	EQUAL_TO
	après	DateTime	EQUAL_TO
	avant	DateTime	EQUAL_TO
	order	Chaîne	EQUAL_TO
	commander par	Chaîne	EQUAL_TO
	customer	Entier	EQUAL_TO
	produit	Entier	EQUAL_TO

Entité	Champ	Type de données	Opérateurs pris en charge
	pdd	Entier	EQUAL_TO
	modifié_avant	DateTime	EQUAL_TO
	modifié_après	DateTime	EQUAL_TO
	les dates sont GMT	Booléen	EQUAL_TO
total de la commande	limace	Chaîne	N/A
	name	Chaîne	N/A
	total	Entier	N/A
passerelle de paiement	title	Chaîne	N/A
	description	Chaîne	N/A
	order	Chaîne	N/A
	enabled	Booléen	N/A
	titre_méthode	Chaîne	N/A
	description de la méthode	Chaîne	N/A
	support_méthodes	Liste	N/A
	paramètres	Chaîne	N/A
	configuration des besoins	Booléen	N/A
	scripts de post-installation	Liste	N/A
	URL des paramètres	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	URL_de connexion	Chaîne	N/A
	texte_d'aide à la configuration	Chaîne	N/A
	Clés de paramètres obligatoires	Liste	N/A
produit	id	Entier	N/A
	name	Chaîne	N/A
	type	Chaîne	EQUAL_TO
	permalien	Chaîne	N/A
	date_créée	DateTime	N/A
	date de création_gmt	DateTime	N/A
	date_modifiée	DateTime	N/A
	date_modifié_gmt	DateTime	N/A
	visibilité du catalogue	Chaîne	N/A
	description	Chaîne	N/A
	short_description	Chaîne	N/A
	prix	Chaîne	N/A
	prix_régulier	Chaîne	N/A
	prix_de vente	Chaîne	N/A
	date de mise en vente	DateTime	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	date de mise en vente à partir de l'heure GMT	DateTime	N/A
	date de vente au	DateTime	N/A
	date de mise en vente jusqu'à l'heure GMT	DateTime	N/A
	prix_html	Chaîne	N/A
	achetable	Booléen	N/A
	ventes totales	Entier	N/A
	virtuel	Booléen	N/A
	téléchargeable	Booléen	N/A
	téléchargements	Liste	N/A
	limite_de_téléchargement	Entier	N/A
	expiration_téléchargement	Entier	N/A
	URL_externe	Chaîne	N/A
	bouton_texte	Chaîne	N/A
	statut_fiscal	Chaîne	N/A
	gérer_stock	Booléen	N/A
	stock_quantité	Entier	N/A
	en rupture de stock	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	arriérés de commandes_authorized	Booléen	N/A
	en rupture de stock	Booléen	N/A
	vendu_individuellement	Booléen	N/A
	poids	Chaîne	N/A
	dimensions	Struct	N/A
	expédition_obligatoire	Booléen	N/A
	expédition_taxable	Booléen	N/A
	identifiant_classe d'expédition	Entier	N/A
	commentaires_authorized	Booléen	N/A
	notation_moyenne	Chaîne	N/A
	notation_count	Entier	N/A
	identifiant_associés	Liste	N/A
	upsell_ids	Liste	N/A
	identifiants de vente croisés	Liste	N/A
	identifiant_parent	Entier	N/A
	note_d'achat	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	categories	Liste	N/A
	balises	Liste	N/A
	images	Liste	N/A
	attributs	Liste	N/A
	attributs_par défaut	Liste	N/A
	variantes	Liste	N/A
	produits_groupés	Liste	N/A
	menu_order	Entier	N/A
	méta-données	Liste	N/A
	faible montant du stock	Entier	N/A
	jetpack_publicize_connections	Liste	N/A
	jetpack-related-posts	Liste	N/A
	jetpack_likes_enabled	Booléen	N/A
	jetpack_sharing_enabled	Booléen	N/A
	context	Chaîne	EQUAL_TO
	search	Chaîne	EQUAL_TO
	après	DateTime	EQUAL_TO
	avant	DateTime	EQUAL_TO

Entité	Champ	Type de données	Opérateurs pris en charge
	order	Chaîne	EQUAL_TO
	commander par	Chaîne	EQUAL_TO
	limace	Chaîne	EQUAL_TO
	status	Chaîne	EQUAL_TO
	sku	Chaîne	EQUAL_TO
	en avant	Booléen	EQUAL_TO
	balise	Chaîne	EQUAL_TO
	classe_expédition	Chaîne	EQUAL_TO
	classe_taxe	Chaîne	EQUAL_TO
	en vente	Booléen	EQUAL_TO
	état_du stock	Chaîne	EQUAL_TO
	a des options	Booléen	N/A
	modifié_après	DateTime	EQUAL_TO
	modifié_avant	DateTime	EQUAL_TO
	les dates sont GMT	Booléen	EQUAL_TO
	category	Chaîne	EQUAL_TO
	attribute	Chaîne	EQUAL_TO
	prix_minimum	Chaîne	EQUAL_TO
	max_price	Chaîne	EQUAL_TO
attribut du produit	id	Entier	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	name	Chaîne	N/A
	limace	Chaîne	N/A
	type	Chaîne	N/A
	commande_par	Chaîne	N/A
	possède des archives	Booléen	N/A
	context	Chaîne	EQUAL_TO
product-attribute-term	id	Entier	N/A
	name	Chaîne	N/A
	limace	Chaîne	N/A
	description	Chaîne	N/A
	menu_order	Entier	N/A
	count	Entier	N/A
	context	Chaîne	EQUAL_TO
	search	Chaîne	EQUAL_TO
	order	Chaîne	EQUAL_TO
	commander par	Chaîne	EQUAL_TO
	masquer_vide	Booléen	EQUAL_TO
	parent	Entier	EQUAL_TO
	produit	Entier	EQUAL_TO
catégorie-produit	id	Entier	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	name	Chaîne	N/A
	limace	Chaîne	EQUAL_TO
	description	Chaîne	N/A
	display	Chaîne	N/A
	image	Struct	N/A
	menu_order	Entier	N/A
	count	Entier	N/A
	context	Chaîne	EQUAL_TO
	search	Chaîne	EQUAL_TO
	order	Chaîne	EQUAL_TO
	commander par	Chaîne	EQUAL_TO
	masquer_vide	Booléen	EQUAL_TO
	parent	Entier	EQUAL_TO
	produit	Entier	EQUAL_TO
revue du produit	id	Entier	N/A
	date_créée	DateTime	N/A
	date de création_gmt	DateTime	N/A
	product_id	Entier	N/A
	product_name	Chaîne	N/A
	permalien du produit	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	examen	Chaîne	N/A
	évaluation	Entier	N/A
	verified	Booléen	N/A
	correcteur	Chaîne	N/A
	email_évaluateur	Chaîne	N/A
	urls de l'avatar du réviseur	Struct	N/A
	context	Chaîne	EQUAL_TO
	search	Chaîne	EQUAL_TO
	après	DateTime	EQUAL_TO
	avant	DateTime	EQUAL_TO
	order	Chaîne	EQUAL_TO
	commander par	Chaîne	EQUAL_TO
	status	Chaîne	EQUAL_TO
product-shipping-class	id	Entier	N/A
	name	Chaîne	N/A
	limace	Chaîne	EQUAL_TO
	description	Chaîne	N/A
	count	Entier	N/A
	context	Chaîne	EQUAL_TO

Entité	Champ	Type de données	Opérateurs pris en charge
	search	Chaîne	EQUAL_TO
	order	Chaîne	EQUAL_TO
	commander par	Chaîne	EQUAL_TO
	masquer_vide	Chaîne	EQUAL_TO
	produit	Entier	EQUAL_TO
étiquette du produit	id	Entier	N/A
	name	Chaîne	N/A
	limace	Chaîne	EQUAL_TO
	description	Chaîne	N/A
	count	Entier	N/A
	context	Chaîne	EQUAL_TO
	search	Chaîne	EQUAL_TO
	order	Chaîne	EQUAL_TO
	commander par	Chaîne	EQUAL_TO
	masquer_vide	Booléen	EQUAL_TO
	produit	Entier	EQUAL_TO
total du produit	limace	Chaîne	N/A
	name	Chaîne	N/A
	total	Entier	N/A
variation du produit	id	Entier	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	date_créée	DateTime	N/A
	date de création_gmt	DateTime	N/A
	date_modifiée	DateTime	N/A
	date_modifié_gmt	DateTime	N/A
	description	Chaîne	N/A
	permalien	Chaîne	N/A
	prix	Chaîne	N/A
	prix_régulier	Chaîne	N/A
	prix_de vente	Chaîne	N/A
	date de mise en vente	DateTime	N/A
	date de mise en vente à partir de l'heure GMT	DateTime	N/A
	date de vente au	DateTime	N/A
	date de mise en vente jusqu'à l'heure GMT	DateTime	N/A
	achetable	Booléen	N/A
	virtuel	Booléen	N/A
	téléchargeable	Booléen	N/A
	téléchargements	Liste	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	limite_de_téléchargement	Entier	N/A
	expiration_téléchargement	Entier	N/A
	statut_fiscal	Chaîne	N/A
	gérer_stock	Booléen	N/A
	stock_quantité	Entier	N/A
	en rupture de stock	Chaîne	N/A
	arriérés de commandes autorisés	Booléen	N/A
	en rupture de stock	Booléen	N/A
	faible montant du stock	Entier	N/A
	poids	Chaîne	N/A
	dimensions	Struct	N/A
	classe_expédition	Chaîne	N/A
	identifiant_classe d'expédition	Entier	N/A
	image	Struct	N/A
	attributs	Liste	N/A
	menu_order	Entier	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	méta-données	Liste	N/A
	context	Chaîne	EQUAL_TO
	search	Chaîne	EQUAL_TO
	après	DateTime	EQUAL_TO
	avant	DateTime	EQUAL_TO
	order	Chaîne	EQUAL_TO
	commander par	Chaîne	EQUAL_TO
	limace	Chaîne	EQUAL_TO
	status	Chaîne	EQUAL_TO
	sku	Chaîne	EQUAL_TO
	classe_taxe	Chaîne	EQUAL_TO
	en vente	Booléen	EQUAL_TO
	prix_minimum	Chaîne	EQUAL_TO
	max_price	Chaîne	EQUAL_TO
	état_du stock	Chaîne	EQUAL_TO
report	limace	Chaîne	N/A
	description	Chaîne	N/A
total de l'évaluation	limace	Chaîne	N/A
	name	Chaîne	N/A
	total	Entier	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
rapport des ventes	ventes totales	Chaîne	N/A
	ventes nettes	Chaîne	N/A
	ventes moyennes	Chaîne	N/A
	nombre total de commandes	Entier	N/A
	total_articles	Entier	N/A
	impôt_total	Chaîne	N/A
	expédition totale	Chaîne	N/A
	remboursement_totaux	Entier	N/A
	remise totale	Chaîne	N/A
	totals_groupé_par	Chaîne	N/A
	totaux	Struct	N/A
	nombre total de clients	Entier	N/A
	context	Chaîne	EQUAL_TO
	point	Chaîne	EQUAL_TO
	date_minute	Date	EQUAL_TO
	date_max	Date	EQUAL_TO
méthode d'expédition	id	Chaîne	N/A
	title	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
zone d'expédition	description	Chaîne	N/A
	id	Entier	EQUAL_TO
	name	Chaîne	N/A
	order	Entier	N/A
shipping-zone-location	code	Chaîne	N/A
	type	Chaîne	N/A
shipping-zone-method	instance_id	Entier	N/A
	id	Entier	EQUAL_TO
	title	Chaîne	N/A
	order	Entier	N/A
	enabled	Booléen	N/A
	identifiant_méthode	Chaîne	N/A
	titre_méthode	Chaîne	N/A
	description de la méthode	Chaîne	N/A
	paramètres	Struct	N/A
classe fiscale	limace	Chaîne	N/A
	name	Chaîne	N/A
taux d'imposition	id	Entier	N/A
	country	Chaîne	N/A

Entité	Champ	Type de données	Opérateurs pris en charge
	state	Chaîne	N/A
	code postal	Chaîne	N/A
	city	Chaîne	N/A
	codes postaux	Liste	N/A
	villes	Liste	N/A
	taux	Chaîne	N/A
	name	Chaîne	N/A
	priority	Entier	N/A
	composé	Booléen	N/A
	livraison	Booléen	N/A
	context	Chaîne	EQUAL_TO
	order	Chaîne	EQUAL_TO
	commander par	Chaîne	EQUAL_TO
	class	Chaîne	EQUAL_TO
top-seller-report	name	Chaîne	N/A
	product_id	Entier	N/A
	quantity	Entier	N/A
	context	Chaîne	EQUAL_TO
	point	Chaîne	EQUAL_TO
	date_minute	Date	EQUAL_TO

Entité	Champ	Type de données	Opérateurs pris en charge
	date_max	Date	EQUAL_TO

Note

Les types de données Struct et List sont convertis en type de données String, et le type de DateTime données est converti en Timestamp dans la réponse des connecteurs.

Requêtes de partitionnement

Partitionnement basé sur des enregistrements :

Vous pouvez fournir l'option Spark supplémentaire NUM_PARTITIONS si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en NUM_PARTITIONS plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

Dans le partitionnement basé sur les enregistrements, le nombre total d'enregistrements présents est demandé par l' WooCommerce API et divisé par le nombre fourni. NUM_PARTITIONS Le nombre d'enregistrements qui en résulte est ensuite extrait simultanément par chaque sous-requête.

- NUM_PARTITIONS: le nombre de partitions.

Les entités suivantes prennent en charge le partitionnement basé sur les enregistrements :

- coupon
- order
- produit
- attribut du produit
- product-attribute-term
- catégorie-produit
- revue du produit
- product-shipping-class

- étiquette du produit
- variation du produit
- taux d'imposition

Exemple :

```
woocommerce_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="glue.spark.woocommerce",  
    connection_options={  
        "connectionName": "connectionName",  
        "ENTITY_NAME": "coupon",  
        "API_VERSION": "v3",  
        "INSTANCE_URL": "instanceUrl",  
        "NUM_PARTITIONS": "10"  
    }  
)
```

Partitionnement basé sur des enregistrements :

La requête d'origine est divisée en NUM_PARTITIONS plusieurs sous-requêtes qui peuvent être exécutées simultanément par les tâches Spark :

- NUM_PARTITIONS: le nombre de partitions.

Exemple :

```
WooCommerce_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="WooCommerce",  
    connection_options={  
        "connectionName": "connectionName",  
        "REALMID": "1234567890123456789",  
        "ENTITY_NAME": "Bill",  
        "API_VERSION": "v3",  
        "NUM_PARTITIONS": "10"  
    }  
)
```

WooCommerce options de connexion

Les options de connexion suivantes sont disponibles pour WooCommerce :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans WooCommerce.
- API_VERSION(Chaîne) - (Obligatoire) Utilisé pour la lecture. WooCommerce Version de l'API Rest que vous souhaitez utiliser.
- REALM_ID(Chaîne) - Un identifiant identifiant une entreprise WooCommerce en ligne individuelle à laquelle vous envoyez des demandes.
- SELECTED_FIELDS(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- FILTER_PREDICATE(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- QUERY(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- INSTANCE_URL(String) - (Obligatoire) Une URL d' WooCommerce instance valide au format : `https ://<instance>.wpcomstaging.com`
- NUM_PARTITIONS(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.

Connexion à Zendesk

Zendesk est une solution de gestion de centre d'assistance basée sur le cloud qui propose des outils personnalisables pour créer un portail de service client, une base de connaissances et des communautés en ligne.

Rubriques

- [AWS Glue support pour Zendesk](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Zendesk](#)
- [Configuration des connexions Zendesk](#)
- [Lecture depuis des entités Zendesk](#)
- [Options de connexion Zendesk](#)
- [Limites](#)

AWS Glue support pour Zendesk

AWS Glue prend en charge Zendesk comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Zendesk.

Soutenu en tant que cible ?

Non

Versions d'API Zendesk prises en charge

Les versions d'API Zendesk suivantes sont prises en charge

- v2

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources

spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Zendesk

Avant de pouvoir AWS Glue transférer des données depuis Zendesk, vous devez répondre aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un compte Zendesk. Pour de plus amples informations, veuillez consulter [Création d'un compte Zendesk](#).
- Votre compte Zendesk est activé pour accéder à l'API.
- Votre compte Zendesk vous permet d'installer des applications connectées.

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Zendesk.

Création d'un compte Zendesk

Pour créer un compte Zendesk :

1. Accéder à l' <https://www.zendesk.com/in/enregistrement/>
2. Entrez les informations telles que votre adresse e-mail professionnelle, votre prénom, votre nom de famille, votre numéro de téléphone, le titre du poste, le nom de l'entreprise, le nombre d'employés de l'entreprise, le mot de passe et la langue préférée. Choisissez ensuite l'inscription complète à l'essai.
3. Une fois votre compte créé, complétez le lien de vérification que vous avez reçu pour vérifier votre adresse e-mail.

4. Une fois l'adresse e-mail professionnelle vérifiée, vous êtes redirigé vers votre compte Zendesk. Choisissez l'option Acheter Zendesk pour votre forfait préféré. Remarque : pour le connecteur Zendesk, il est recommandé d'acheter le plan Suite Enterprise.

Création d'une application cliente et d'informations d'identification OAuth 2.0

Pour créer une application cliente et des informations d'identification OAuth 2.0 :

1. Connectez-vous à votre compte Zendesk dans lequel vous souhaitez que l'application OAuth 2.0 soit créée <https://www.zendesk.com/in/login/>
2. Cliquez sur l'icône représentant une roue dentée. Cliquez sur le lien Accéder au centre d'administration pour ouvrir la page du centre d'administration.
3. Choisissez Applications et intégrations dans la barre latérale gauche, puis sélectionnez APIs> API Zendesk.
4. Sur la page de l'API Zendesk, choisissez l'onglet OAuth Clients.
5. Choisissez Ajouter un client Oauth sur le côté droit.
6. Renseignez les champs suivants pour créer un client :
 - a. Nom du client - Entrez le nom de votre application. Il s'agit du nom que les utilisateurs verront lorsqu'on leur demandera d'autoriser l'accès à votre application et lorsqu'ils consulteront la liste des applications tierces ayant accès à leur Zendesk.
 - b. Description - Facultatif. Brève description de votre application que les utilisateurs verront lorsqu'on leur demandera d'autoriser l'accès à celle-ci.
 - c. Entreprise - Facultatif. Le nom de l'entreprise que les utilisateurs verront lorsqu'ils seront invités à autoriser l'accès à votre application. Ces informations peuvent les aider à comprendre à qui ils accordent l'accès.
 - d. Logo - Facultatif. Il s'agit du logo que les utilisateurs verront lorsqu'on leur demandera d'autoriser l'accès à votre application. L'image peut être au format JPG, GIF ou PNG. Pour de meilleurs résultats, importez une image carrée. Il sera redimensionné pour la page d'autorisation.
 - e. Identifiant unique : le champ est rempli automatiquement avec une version reformatée du nom que vous avez saisi pour votre application. Vous pouvez modifier les noms si vous le souhaitez.
 - f. Redirection URLs : entrez l'URL ou l'URL URLs que Zendesk doit utiliser pour envoyer la décision de l'utilisateur d'autoriser l'accès à votre application.

Par exemple : <https://us-east-1.console.aws.amazon.com/gluestudio/oauth>

7. Cliquez sur Sauvegarder
8. Une fois la page actualisée, un nouveau champ secret prérempli apparaît en bas de la page. Il s'agit de la valeur « client_secret » spécifiée dans la OAuth2 spécification. Copiez la valeur Secret dans votre presse-papiers et enregistrez-la dans un endroit sûr. Remarque : Les caractères peuvent dépasser la largeur de la zone de texte. Assurez-vous donc de tout sélectionner avant de copier.
9. Cliquez sur Sauvegarder

Configuration des connexions Zendesk

Le connecteur Zendesk prend en charge le type d'octroi de code d'autorisation.

- Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers un serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. L'utilisateur qui crée une connexion peut par défaut s'appuyer sur une application connectée qu'il AWS Glue possède (application client AWS Glue gérée) pour laquelle il n'a pas besoin de fournir d'informations OAuth connexes, à l'exception de l'URL de son instance Zendesk. La AWS Glue console redirige l'utilisateur vers Zendesk où il doit se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Zendesk.
- Vous pouvez toujours choisir de créer votre propre application connectée dans Zendesk et de fournir votre propre identifiant client et votre secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, vous serez toujours redirigé vers Zendesk pour vous connecter et autoriser l'accès AWS Glue à vos ressources.
- Ce type de subvention donne lieu à un jeton d'accès. Le jeton d'accès n'expire jamais.

Pour consulter la documentation publique de Zendesk sur la création d'une application connectée pour le OAuth flux de code d'autorisation, consultez la section [OAuth Tokens pour les types de subvention](#).

Pour configurer une connexion Zendesk :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour le type de AuthorizationCode subvention : pour une application connectée gérée par le client, le secret doit contenir le secret du consommateur de l'application connectée avec USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET comme clé.

- b. Remarque : Vous devez créer un secret par connexion dans AWS Glue.
2. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Zendesk.
 - b. Indiquez l'INSTANCE_URL du Zendesk auquel vous souhaitez vous connecter.
 - c. Fournissez l'environnement Zendesk.
 - d. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- e. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
- f. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
3. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

Lecture depuis des entités Zendesk

Prérequis

Un objet Zendesk dont vous aimeriez lire un extrait. Vous aurez besoin du nom de l'objet tel que ticket, utilisateur ou article, comme indiqué dans le tableau suivant.

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Billet	Y	Y	Y	Y	N
Utilisateur	Y	Y	Y	Y	N
Organisation	Y	Y	Y	Y	N
L'article	Y	Y	N	Y	N
Événement avec billetterie	Y	Y	N	Y	N
Événement Ticket Metric	Y	Y	N	Y	N
Commentaire sur le billet	Y	Y	Y	Y	N
Champ de ticket	Y	Y	N	Y	N
Métrique du billet	Y	Y	N	Y	N
Activité sur les tickets	Y	Y	N	Y	N
Ignorer les billets	N	Y	N	Y	N
Groupe	Y	Y	Y	Y	N
Adhésion à un groupe	N	Y	Y	Y	N

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Cote de satisfaction	Y	Y	N	Y	N
Vue	Y	Y	Y	Y	N
Déclencheur	Y	Y	Y	Y	N
Catégorie de déclencheur	N	Y	Y	Y	N
Macro	Y	Y	Y	Y	N
Automatisation	N	Y	Y	Y	N

Exemple :

```
Zendesk_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Zendesk",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v2"
    }
)
```

Entités Zendesk et détails des champs :

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
articles	url	Chaîne		
	id	Long		
	identifiant_auteur	Long		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	body	Chaîne		
	commentaires_désactivés	Booléen		
	ébauche	Booléen		
	edited_at	DateTime		
	url_html	Chaîne		
	nom_de_étiquette	Liste		
	locale	Chaîne	EQUAL_TO	
	dépassé	Booléen		
	locales_périmées	Liste		
	identifiant_groupe_autorisation	Long		
	position	Entier		
	promu	Booléen		
	identifiant_section	Long		
	source_locale	Chaîne		
	name	Chaîne		
	title	Chaîne		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	identifiant_segment_utilisateur	Long		
	identifiant des balises de contenu	Liste		
	nombre de votes	Entier		
	somme des votes	Entier		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	nom_étiquette	Chaîne	EQUAL_TO	
groupe	url	Chaîne		
	id	Long		
	is_public	Booléen		
	name	Chaîne		
	description	Chaîne		
	default	Booléen		
	deleted	Booléen		
	created_at	DateTime		
	updated_at	DateTime		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	exclude_s upprimé	Booléen	EQUAL_TO	
Automatisation	url	Chaîne		
	id	Long		
	title	Chaîne		
	actif	Booléen		
	created_at	DateTime		
	updated_at	DateTime		
	default	Booléen		
	actions	Liste		
	positions	Entier		
	conditions	Struct		
	titre brut	Chaîne		
adhésion à un groupe	url	Chaîne		
	id	Long		
	user_id	Long		
	group_id	Long		
	default	Booléen		
	created_at	DateTime		
	updated_at	DateTime		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
macro	url	Chaîne		
	id	Long		
	title	Chaîne		
	actif	Booléen	EQUAL_TO	
	created_at	DateTime		
	updated_at	DateTime		
	default	Booléen		
	actions	Liste		
	position	Entier		
	description	Chaîne		
	titre brut	Chaîne		
	restriction	Struct		
	accès	Chaîne	EQUAL_TO	
	category	Entier	EQUAL_TO	
	group_id	Long	EQUAL_TO	
	uniquement consultable	Booléen	EQUAL_TO	
organisations	url	Chaîne		
	id	Long		
	external_id	Chaîne		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	name	Chaîne		
	nom_domaines	Liste		
	détails	Chaîne		
	notes	Chaîne		
	group_id	Long		
	tickets partagés	Booléen		
	commentaires partagés	Booléen		
	balises	Liste		
	domaines_d'organisation	Struct		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	DML_STATUS	Chaîne		Champ défini par l'utilisateur utilisé pour suivre le statut créé, mis à jour et supprimé de l'enregistrement.
cote de satisfaction	url	Chaîne		
	id	Long		
	assignee_id	Long		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	comment	Chaîne		
	group_id	Long		
	raison	Chaîne		
	code_raisonnable	Entier		
	identifiant_motif	Long		
	requester_id	Long		
	score	Chaîne	EQUAL_TO	
	identifiant du ticket	Entier		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	start_time	DateTime	EQUAL_TO	
	end_time	DateTime	EQUAL_TO	
	DML_STATUS	Chaîne		Champ défini par l'utilisateur utilisé pour suivre le statut créé, mis à jour et supprimé de l'enregistrement.
activité des billets	acteur	Struct		
	actor_id	Long		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	created_at	DateTime		
	id	Long		
	objet	Struct		
	cible	Struct		
	title	Chaîne		
	updated_at	DateTime		
	url	Chaîne		
	utilisateur	Struct		
	user_id	Long		
	verb	Chaîne		
	since	DateTime	EQUAL_TO	
commentaire sur le ticket	id	Long		
	type	Chaîne		
	identifiant_auteur	Long		
	body	Chaîne		
	html_body	Chaîne		
	corps uni	Chaîne		
	public	Booléen		
	pièces jointes	Liste		
	identifiant_audit	Long		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	via	Struct		
	created_at	DateTime		
	métadonnées	Struct		
	identifiant du ticket	Entier	EQUAL_TO	
	inclure des images en ligne	Booléen	EQUAL_TO	
billetteries	id	Long		
	identifiant du ticket	Long		
	timestamp	Long		
	created_at	DateTime		
	id_de mise à jour	Long		
	événements pour enfants	Liste		
	via	Chaîne		
	system	Struct		
	event_type	Chaîne		
	commentaire_présent	Booléen		
	commentaire_public	Booléen		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	via_reference_id	Long		
	created_at	DateTime	EQUAL_TO	
	DML_STATUS	Chaîne		Champ défini par l'utilisateur utilisé pour suivre le statut créé, mis à jour et supprimé de l'enregistrement.
billetterie	url	Chaîne		
	id	Long		
	type	Chaîne		
	title	Chaîne		
	titre brut	Chaîne		
	description	Chaîne		
	description brute	Chaîne		
	position	Entier		
	actif	Booléen		
	obligatoire	Booléen		
	replié pour les agents	Booléen		
	regex_pour_validation	Chaîne		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	title_in_portal	Chaîne		
	raw_title_in_portal	Chaîne		
	visible dans le portail	Booléen		
	modifiable sur le portail	Booléen		
	requis_in_portal	Booléen		
	balise	Chaîne		
	created_at	DateTime		
	updated_at	DateTime		
	amovable	Booléen		
	description_de l'agent	Chaîne		
	options de champ personnalisées	Liste		
	status_personnalisés	Liste		
	filtre_relationnel	Struct		
	type_cible_relation	Chaîne		
	ID de sous-type	Entier		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	options de champ du système	Liste		
	locale	Chaîne	EQUAL_TO	
ticket-metric-events	id	Long		
	time	DateTime	EQUAL_TO	
	identifiant du ticket	Entier		
	métrique	Chaîne		
	instance_id	Entier		
	type	Chaîne		
	DML_STATUS	Chaîne	EQUAL_TO	Champ défini par l'utilisateur utilisé pour suivre le statut créé, mis à jour et supprimé de l'enregistrement.
Ticket-Metric	url	Chaîne		
	id	Long		
	identifiant du ticket	Entier		
	created_at	DateTime		
	updated_at	DateTime		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	stations de groupe	Entier		
	stations_ assignées	Entier		
	rouvre	Entier		
	réponses	Entier		
	assignee_ updated_at	DateTime		
	requester_ updated_at	DateTime		
	initialem ent_assigned_at	DateTime		
	assigné à	DateTime		
	solved_at	DateTime		
	last_comm ent_added_at	DateTime		
	temps_de réponse en minutes	Struct		
	durée de la première résolution en minutes	Struct		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	temps_de résolution complète en minutes	Struct		
	temps d'attente de l'agent en minutes	Struct		
	Le délai d'attente du demandeur en minutes	Struct		
	durée de mise en attente en secondes	Struct		
	temps_de réponse en secondes	Struct		
	custom_status_updated_at	DateTime		
ticket skip	created_at	DateTime		
	id	Long		
	raison	Chaîne		
	ticket	Struct		
	identifiant du ticket	Entier		
	updated_at	DateTime		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
billets	user_id	Long		
	url	Chaîne		
	id	Long		
	external_id	Chaîne	EQUAL_TO	
	type	Chaîne		
	subject	Chaîne		
	raw_subject	Chaîne		
	description	Chaîne		
	priority	Chaîne		
	status	Chaîne		
	destinataire	Chaîne		
	demandeur	Struct		
	requester_id	Long		
	submitter_id	Long		
	assignee_id	Long		
	organization_id	Long		
	group_id	Long		
	collaborator_ids	Liste		
	emails_cc_ids	Liste		
	follower_ids	Liste		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	forum_topic_id	Ling		
	problem_id	Long		
	has_incidents	Booléen		
	due_at	DateTime		
	balises	Liste		
	via	Struct		
	custom_fields	Liste		
	satisfaction_rating	Struct		
	sharing_agreement_ids	Liste		
	followup_ids	Liste		
	via_followup_source_id	Long		
	ticket_form_id	Long		
	brand_id	Long		
	allow_channelback	Booléen		
	allow_attachments	Booléen		
	is_public	Booléen		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	from_messaging_channel	Booléen		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	courriel_destinataire	Chaîne		
	identifiant_valeur_attributs	Liste		
	collaborateurs	Liste		
	comment	Struct		
	identifiant_statut_personnalisé	Long		
	email_ccs	Struct		
	suiveurs	Struct		
	macro_id	Long		
	macros_ids	Liste		
	métadonnées	Struct		
	mise à jour sécurisée	Booléen		
	timbre_mis à jour	DateTime		
	via_id	Long		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	voice_commentaire	Struct		
	DML_STATUS	Chaîne		Champ défini par l'utilisateur utilisé pour suivre le statut créé, mis à jour et supprimé de l'enregistrement.
catégorie-déclencheur	url	Chaîne		
	id	Chaîne		
	name	Chaîne		
	updated_at	DateTime		
	created_at	DateTime		
	position	Entier		
déclencheur	url	Chaîne		
	id	Long		
	title	Chaîne		
	actif	Booléen	EQUAL_TO	
	updated_at	DateTime		
	created_at	DateTime		
	default	Booléen		
	actions	Liste		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	conditions	Struct		
	description	Chaîne		
	position	Entier		
	titre brut	Chaîne		
	identifiant_catégorie	Chaîne	EQUAL_TO	
utilisateurs	url	Chaîne		
	id	Long		
	external_id	Chaîne	EQUAL_TO	
	e-mail	Chaîne		
	actif	Booléen		
	alias	Chaîne		
	chat_only	Booléen		
	identifiant de rouleur personnalisé	Long		
	roll_type	Entier		
	détails	Chaîne		
	last_login_at	DateTime		
	locale	Chaîne		
	locale_id	Entier		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	moderator	Booléen		
	notes	Chaîne		
	name	Chaîne		
	only_priv ate_comments	Booléen		
	organization_id	Long		
	default_group_id	Long		
	phone	Chaîne		
	photo	Struct		
	URL de la photo_tél écommande	Chaîne		
	restricted_agent	Booléen		
	rôle	Chaîne	EQUAL_TO	
	shared	Booléen		
	agent_partagé	Booléen		
	balise	Liste		
	Signature	Chaîne		
	suspended	Booléen		
	ticket_restriction	Chaîne		
	time_zone	Chaîne		

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	IANA_Time_Zone			
	two_factor_auth_enabled			
	user_fields			
	verified	Booléen		
	report_csv	Booléen		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	ensemble d'autorisations	Long	EQUAL_TO	
	shared_phone_number	Booléen		
	DML_STATUS	Chaîne		Champ défini par l'utilisateur utilisé pour suivre le statut créé, mis à jour et supprimé de l'enregistrement.
afficher	url	Chaîne		
	id	Long		
	title	Chaîne		
	actif	Booléen	EQUAL_TO	

Entité	Champ	Type de données	Opérateurs pris en charge	Commentaires
	updated_at	DateTime		
	created_at	DateTime		
	default	Booléen		
	position	Entier		
	description	Chaîne		
	execution	Struct		
	restriction	Struct		
	titre brut	Chaîne		
	conditions	Struct		
	accès	Chaîne	EQUAL_TO	
	group_id	Long	EQUAL_TO	

Note

Les types de données Struct et List sont convertis en type de données String dans la réponse du connecteur.

Requêtes de partitionnement

Les partitions ne sont pas prises en charge dans Zendesk.

Options de connexion Zendesk

Les options de connexion pour Zendesk sont les suivantes :

- ENTITY_NAME(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Zendesk.

- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Zendesk Rest que vous souhaitez utiliser. Par exemple : v2.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet. Par exemple : id, name, url, created_at
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL. Par exemple : group_id = 100
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète. Par exemple : « SELECT id, url FROM users WHERE role= \"end-user\" »
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête. Le champ par défaut est update_at destiné aux entités prenant en charge l'API d'exportation incrémentielle (created_at pour ticket-events et time pour ticket-metric-events).
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi. Facultatif ; cette option sera gérée par le connecteur si elle n'est pas fournie dans l'option de tâche. Valeur par défaut - « 2024-05-01T 20:55:02.000 Z
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire. Facultatif ; cette option sera gérée par le connecteur si elle n'est pas fournie dans l'option de tâche. Valeur par défaut : 1.
- **IMPORT_DELETED_RECORDS**(String) - Par défaut : FALSE. Utilisé pour lire. Pour obtenir les enregistrements supprimés lors de la requête.
- **ACCESS_TOKEN**- Jeton d'accès à utiliser dans la demande.
- **INSTANCE_URL**- URL de l'instance sur laquelle l'utilisateur souhaite exécuter les opérations. Par exemple : https://{subdomain}.zendesk.com

Limites

Les limites du connecteur Zendesk sont les suivantes :

- La pagination basée sur le décalage limite le nombre de pages pouvant être extraites à 100, mais elle n'est pas recommandée car le nombre total d'enregistrements pouvant être extraits est de 10 000. Cependant, la pagination basée sur un curseur implémentée pour le connecteur Zendesk permet de contourner cette limitation. Seul l'opérateur de filtre EQUAL_TO est pris en charge par l'API Zendesk.

En raison de cette limitation, le partitionnement n'est pas pris en charge pour le connecteur Zendesk.

- Pour l'entité « Ticket Event », la limite de débit est de 10 demandes par minute. Lors de l'exécution d'une tâche AWS Glue ETL, vous pouvez recevoir une erreur 429 (trop de demandes).

Connexion à Zoho CRM

Zoho CRM agit comme un référentiel unique pour regrouper les activités de vente, de marketing et de support client, et rationaliser les processus, les politiques et les personnes sur une seule plateforme. Zoho CRM peut être facilement personnalisé pour répondre aux besoins spécifiques de tout type et de toute taille d'entreprise.

La plateforme de développement de Zoho CRM offre la bonne combinaison d'outils low-code et pro-code pour les entreprises/entreprises afin d'automatiser le travail, d'intégrer les données dans l'ensemble de l'entreprise et de créer des solutions personnalisées pour le Web et le mobile.

Rubriques

- [AWS Glue support pour Zoho CRM](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Zoho CRM](#)
- [Configuration des connexions Zoho CRM](#)
- [Lecture depuis les entités Zoho CRM](#)
- [Options de connexion Zoho CRM](#)
- [Limitations et remarques relatives au connecteur Zoho CRM](#)

AWS Glue support pour Zoho CRM

AWS Glue prend en charge Zoho CRM comme suit :

Supportée en tant que source ?

Oui — Synchronisation et asynchronisation. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Zoho CRM.

Soutenu en tant que cible ?

Non.

Versions d'API Zoho CRM prises en charge

Les versions suivantes de l'API Zoho CRM sont prises en charge :

- v7

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs

bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Zoho CRM

Avant de pouvoir AWS Glue transférer des données depuis Zoho CRM, vous devez répondre aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous possédez un compte Zoho CRM.
- Votre compte Zoho CRM est activé pour accéder à l'API.
- Vous avez un client d'API enregistré dans la console API pour obtenir des OAuth informations d'identification.

Configuration des connexions Zoho CRM

Le type de subvention détermine le mode AWS Glue de communication avec Zoho CRM pour demander l'accès à vos données. Votre choix influe sur les exigences que vous devez respecter avant de créer la connexion. Zoho CRM prend uniquement en charge le type de subvention `AUTHORIZATION_CODE` pour la version 2.0. OAuth

- Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers un serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. La AWS Glue console redirige l'utilisateur vers Zoho CRM où il doit se connecter et accorder à Glue les autorisations demandées pour accéder à son instance Zoho CRM.
- Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans Zoho CRM et de fournir leur propre identifiant client, URL d'authentification, URL de jeton et URL d'instance lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Zoho CRM pour se connecter et autoriser l'accès AWS Glue à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès restera valide pendant une heure et pourra être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.

- Pour consulter la documentation publique de Zoho CRM sur la création d'une application connectée pour le OAuth flux de code d'autorisation, consultez [Authentification](#).

Pour configurer une connexion Zoho CRM, procédez comme suit :

1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Zoho CRM.
 - b. Indiquez INSTANCE_URL l'instance Zoho CRM à laquelle vous souhaitez vous connecter.
 - c. Indiquez l'ID client de l'application cliente utilisateur.
 - d. Sélectionnez l'URL d'authentification appropriée dans le menu déroulant.
 - e. Sélectionnez l'URL du jeton appropriée dans le menu déroulant.
 - f. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer les actions suivantes et qui dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2>DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- g. Sélectionnez celui secretName que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
 - h. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de liresecretName.

3. Dans la configuration de votre AWS Glue tâche, fournissez `connectionName` une connexion réseau supplémentaire.

Lecture depuis les entités Zoho CRM

Prérequis

Objets Zoho CRM que vous souhaitez consulter. Vous aurez besoin du nom de l'objet.

Entités prises en charge pour Sync source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Produit (langue française non garantie)	Oui	Oui	Oui	Oui	Oui
Citation	Oui	Oui	Oui	Oui	Oui
Bon de commande	Oui	Oui	Oui	Oui	Oui
Solution	Oui	Oui	Oui	Oui	Oui
Appelez	Oui	Oui	Oui	Oui	Oui
Tâche	Oui	Oui	Oui	Oui	Oui
Événement	Oui	Oui	Oui	Oui	Oui
Facture	Oui	Oui	Oui	Oui	Oui
Compte	Oui	Oui	Oui	Oui	Oui
Contact	Oui	Oui	Oui	Oui	Oui
Vendor	Oui	Oui	Oui	Oui	Oui

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Campagne	Oui	Oui	Oui	Oui	Oui
Deal	Oui	Oui	Oui	Oui	Oui
Plomb	Oui	Oui	Oui	Oui	Oui
Module personnalisé	Oui	Oui	Oui	Oui	Oui
Commande de vente	Oui	Oui	Oui	Oui	Oui
Livres de prix	Oui	Oui	Oui	Oui	Oui
Cas	Oui	Oui	Oui	Oui	Oui

Exemple :

```
zoho_read = glueContext.create_dynamic_frame.from_options(
    connection_type="ZOH0",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v7",
        "INSTANCE_URL": "https://www.zohoapis.in/"
    }
)
```

Entités prises en charge pour la source asynchrone :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Produit (langue	Oui	Non	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
française non garantie)					
Citation	Oui	Non	Non	Oui	Non
Bon de commande	Oui	Non	Non	Oui	Non
Solution	Oui	Non	Non	Oui	Non
Appelez	Oui	Non	Non	Oui	Non
Tâche	Oui	Non	Non	Oui	Non
Événement	Oui	Non	Non	Oui	Non
Facture	Oui	Non	Non	Oui	Non
Compte	Oui	Non	Non	Oui	Non
Contact	Oui	Non	Non	Oui	Non
Vendor	Oui	Non	Non	Oui	Non
Campagne	Oui	Non	Non	Oui	Non
Deal	Oui	Non	Non	Oui	Non
Plomb	Oui	Non	Non	Oui	Non
Module personnalisé	Oui	Non	Non	Oui	Non
Commande de vente	Oui	Non	Non	Oui	Non
Livres de prix	Oui	Non	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Cas	Oui	Non	Non	Oui	Non

Exemple :

```
zoho_read = glueContext.create_dynamic_frame.from_options(
    connection_type="ZOH0",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v7",
        "INSTANCE_URL": "https://www.zohoapis.in/",
        "TRANSFER_MODE": "ASYNC"
    }
)
```

Détails du champ Zoho CRM :

Zoho CRM fournit des points de terminaison permettant de récupérer les métadonnées de manière dynamique pour les entités prises en charge. Par conséquent, le support des opérateurs est capturé au niveau du type de données.

Entité	Type de données	Opérateurs pris en charge
Entités Zoho (toutes les entités)	Entier	! =, =, <, <=, >, >=, ENTRE
	Chaîne	Comme, =, !=
	BigInteger	! =, =, <, <=, >, >=, ENTRE
	Booléen	=
	Double	! =, =, <, <=, >, >=, ENTRE
	BigDecimal	! =, =, <, <=, >, >=, ENTRE
	Date	! =, =, <, <=, >, >=, ENTRE

Entité	Type de données	Opérateurs pris en charge
	DateTime	! =, =, <, <=, >, >=, ENTRE
	Struct	N/A
	Liste	N/A

Requêtes de partitionnement

Le partitionnement n'est pas pris en charge en mode asynchrone.

Partitionnement basé sur des filtres (mode de synchronisation) :

Vous pouvez fournir les options supplémentaires de Spark

`PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND`, et `NUM_PARTITIONS` si vous souhaitez utiliser la simultanéité dans Spark. Avec ces paramètres, la requête d'origine serait divisée en `NUM_PARTITIONS` plusieurs sous-requêtes pouvant être exécutées simultanément par les tâches Spark.

- `PARTITION_FIELD`: le nom du champ à utiliser pour partitionner la requête.
- `LOWER_BOUND`: une valeur inférieure inclusive du champ de partition choisi.

Pour le champ `Datetime`, nous acceptons le format d'horodatage Spark utilisé dans les requêtes SQL Spark.

Exemples de valeurs valides :

```
"2024-09-30T01:01:01.000Z"
```

- `UPPER_BOUND`: une valeur limite supérieure exclusive du champ de partition choisi.
- `NUM_PARTITIONS`: le nombre de partitions.

Exemple :

```
zoho_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="zohocrm",  
    connection_options={  
        "connectionName": "connectionName",
```



```
"ENTITY_NAME": "entityName",  
"API_VERSION": "v7",  
"PARTITION_FIELD": "Created_Time"  
"LOWER_BOUND": "2022-01-01T01:01:01.000Z"  
"UPPER_BOUND": "2024-01-01T01:01:01.000Z"  
"NUM_PARTITIONS": "10"  
}
```

Options de connexion Zoho CRM

Les options de connexion pour Zoho CRM sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Le nom de votre objet dans Zoho CRM.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Rest de Zoho CRM que vous souhaitez utiliser.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Colonnes que vous souhaitez sélectionner pour l'objet.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.
- **PARTITION_FIELD**(String) - Utilisé pour la lecture. Champ à utiliser pour partitionner la requête.
- **LOWER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite inférieure inclusive du champ de partition choisi.
- **UPPER_BOUND**(String) - Utilisé pour la lecture. Une valeur limite supérieure exclusive du champ de partition choisi.
- **NUM_PARTITIONS**(Entier) - Valeur par défaut : 1. Utilisé pour la lecture. Nombre de partitions à lire.
- **INSTANCE_URL**(Chaîne) - (Obligatoire) Utilisé pour la lecture. URL d'instance Zoho CRM valide.
- **TRANSFER_MODE**(String) - Utilisé pour indiquer si la requête doit être exécutée en mode asynchrone.

Limitations et remarques relatives au connecteur Zoho CRM

Voici les limites ou remarques relatives au connecteur Zoho CRM :

- Avec la version v7 de l'API, vous pouvez récupérer un maximum de 100 000 enregistrements. Consultez la [documentation Zoho](#).
- Pour l'entité Event, l'étiquette « Meeting » s'affiche comme indiqué dans la [documentation Zoho](#).
- Pour la fonctionnalité Sélectionner tout :
 - Vous pouvez récupérer un maximum de 50 champs depuis le SaaS pour les appels GET et POST.
 - Si vous souhaitez avoir des données pour un champ spécifique qui n'appartient pas aux 50 premiers champs, vous devez fournir manuellement la liste des champs sélectionnés.
 - Si plus de 50 champs sont sélectionnés, tous les champs au-delà des 50 champs seront rognés et contiendront des données nulles dans Amazon S3.
 - Dans le cas d'une expression de filtre, si la liste de 50 champs fournie par l'utilisateur n'inclut pas « id » et « Created_Time », une exception personnalisée sera déclenchée pour inviter l'utilisateur à inclure ces champs.
- Les opérateurs de filtre peuvent être différents field-to-field même s'ils ont le même type de données. Par conséquent, vous devez spécifier manuellement un opérateur différent pour chaque champ qui déclenche une erreur dans la plateforme SaaS.
- Pour la fonctionnalité Trier par :
 - Les données ne peuvent être triées que selon un seul champ sans expression de filtre, tandis que les données peuvent être triées selon plusieurs champs lorsqu'une expression de filtre est appliquée.
 - Si aucun ordre de tri n'est spécifié pour le champ sélectionné, les données seront extraites par ordre croissant par défaut.
- Les régions prises en charge par le connecteur Zoho CRM sont les États-Unis, l'Europe, l'Inde, l'Australie et le Japon.
- [Limitations](#) de la fonctionnalité de lecture asynchrone :
 - L'ordre limite par et le partitionnement ne sont pas pris en charge en mode asynchrone.
 - En mode asynchrone, nous pouvons transférer des données jusqu'à 500 pages avec 200 000 enregistrements par page.
 - Pendant un intervalle d'une minute, seules 10 demandes sont autorisées à être téléchargées. Lorsque vous dépassez la limite de téléchargement, le système renvoie une erreur HTTP 429 et suspend toutes les demandes de téléchargement pendant une minute avant que le traitement ne puisse reprendre.

- Une fois le travail groupé terminé, vous ne pouvez accéder au fichier téléchargeable que pendant une journée. Après cela, vous ne pouvez plus accéder au fichier via les points de terminaison.
- Un maximum de 200 champs de sélection peuvent être fournis via un point de terminaison. Si vous spécifiez plus de 200 champs de sélection dans un point de terminaison, le système exportera automatiquement tous les champs disponibles pour ce module.
- Les champs externes créés dans un module ne sont pas pris en charge dans Bulk Read APIs.
- Le tri et les Group_by clauses ne sont pas pris en charge via ce point de terminaison d'API.
- Les valeurs des champs contenant des données de santé sensibles ne seront récupérées que lorsque l'option Restreindre l'accès aux données via l'API dans les paramètres de conformité est désactivée. Si l'option est activée, la valeur sera vide dans le résultat.
- Limites de filtration/critères
 - Le nombre maximum de critères pouvant être utilisés dans une requête est de 25.
 - Le filtrage/les critères sur les champs de texte multilignes ne sont pas pris en charge.

Connexion à Zoom Meetings

Zoom Meetings est une plateforme de visioconférence basée sur le cloud qui peut être utilisée pour les réunions par visioconférence, les audioconférences, les webinaires, les enregistrements de réunions et le chat en direct.

Rubriques

- [AWS Glue support pour Zoom Meetings](#)
- [Politiques contenant les opérations d'API pour créer et utiliser des connexions](#)
- [Configuration de Zoom Meetings](#)
- [Configuration de l'application cliente Zoom Meetings](#)
- [Configuration des connexions Zoom Meetings](#)
- [Lecture depuis les entités de Zoom Meetings](#)
- [Options de connexion de Zoom Meetings](#)
- [Limites de Zoom Meetings](#)

AWS Glue support pour Zoom Meetings

AWS Glue prend en charge Zoom Meetings comme suit :

Supportée en tant que source ?

Oui. Vous pouvez utiliser les tâches AWS Glue ETL pour interroger les données de Zoom Meetings.

Soutenu en tant que cible ?

Non.

Versions d'API Zoom Meetings prises en charge

Les versions suivantes de l'API Zoom Meetings sont prises en charge :

- v2

Politiques contenant les opérations d'API pour créer et utiliser des connexions

L'exemple de politique suivant décrit les autorisations AWS IAM requises pour créer et utiliser des connexions. Si vous créez un rôle, créez une politique contenant les éléments suivants :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si vous ne souhaitez pas utiliser la méthode ci-dessus, vous pouvez également utiliser les politiques IAM gérées suivantes :

- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiée dans cette politique, AWS Glue les processus disposent des autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise la console AWS de gestion. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console.

Configuration de Zoom Meetings

Avant de pouvoir AWS Glue transférer des données depuis Zoom Meetings, vous devez satisfaire aux exigences suivantes :

Configuration requise

Les exigences minimales suivantes sont les suivantes :

- Vous avez un compte Zoom Meetings.
- Votre compte Zoom est activé pour accéder à l'API.
- Vous avez créé une OAuth2 application dans votre compte Zoom Meetings. Cette intégration fournit les informations d'identification qui AWS Glue permettent d'accéder à vos données en toute sécurité lorsqu'elle passe des appels authentifiés vers votre compte. Pour de plus amples informations, veuillez consulter [the section called “Configuration de l'application cliente Zoom Meetings”](#).

Si vous répondez à ces exigences, vous êtes prêt à vous connecter AWS Glue à votre compte Zoom Meetings. Pour les connexions classiques, vous n'avez rien d'autre à faire dans Zoom Meetings.

Configuration de l'application cliente Zoom Meetings

1. Connectez-vous au Zoom App Marketplace.
2. Choisissez Développer > Créer une application.
3. Choisissez General App pour une application basée sur la OAuth version 2.0.

4. Sur la page Informations de base, ajoutez ou mettez à jour des informations sur l'application, telles que le nom de l'application, son mode de gestion, ses informations d'identification et autres OAuth informations.
5. Dans la section Sélectionnez le mode de gestion de l'application, confirmez comment vous souhaitez que votre application soit gérée :
 - a. Géré par l'administrateur : les administrateurs du compte ajoutent et gèrent l'application
 - b. Géré par l'utilisateur : des utilisateurs individuels ajoutent et gèrent l'application. L'application n'a accès qu'aux données autorisées de l'utilisateur.
6. Informations d'identification de l'application : le flux de génération génère automatiquement les informations d'identification de l'application (ID client et secret du client) pour votre application.
7. Dans la section OAuth Informations, configurez OAuth votre application.
 - a. OAuth URL de redirection (obligatoire) : entrez l'URL de redirection ou le point de terminaison à configurer OAuth entre votre application et Zoom.
 - b. Utiliser l'URL du mode strict (facultatif)
 - c. Vérification des sous-domaines (facultatif)
 - d. OAuth listes d'autorisation (obligatoire) : ajoutez toute adresse unique URLs que Zoom doit autoriser comme redirections valides pour vos OAuth flux.
8. Sur la page Scopes, sélectionnez les méthodes de l'API Zoom que votre application est autorisée à appeler. Les étendues définissent les informations et les fonctionnalités mises à la disposition de votre utilisateur. Sélectionnez les portées granulaires suivantes :
 - utilisateur:read:list_users:admin
 - zoom_rooms:read:list_rooms:admin
 - group:read:list_members:admin
 - group:read:administrateur:admin
 - group:read:list_groups:admin
 - rapport:read:admin
 - role:read:list_roles, role:read:list_roles:admin

Une fois les étendues ajoutées, choisissez Continuer et l'application est prête à être utilisée.

Pour plus d'informations sur la configuration OAuth 2.0, voir [Intégrations \(OAuth applications\)](#).

Configuration des connexions Zoom Meetings

Zoom Meetings prend en charge le type de subvention `AUTHORIZATION_CODE` pour `OAuth2`. Le type de subvention détermine le mode AWS Glue de communication avec Zoom Meetings pour demander l'accès à vos données.

- Ce type de subvention est considéré comme « à trois étapes » OAuth car il repose sur la redirection des utilisateurs vers un serveur d'autorisation tiers pour authentifier l'utilisateur. Il est utilisé lors de la création de connexions via la AWS Glue console. L'utilisateur qui crée une connexion doit fournir des informations OAuth connexes telles que l'ID client et le secret du client pour son application client Zoom Meetings. La AWS Glue console redirige l'utilisateur vers Zoom où il doit se connecter et autoriser AWS Glue les autorisations demandées pour accéder à son instance Zoom Meetings.
- Les utilisateurs peuvent toujours choisir de créer leur propre application connectée dans Zoom Meetings et de fournir leur propre identifiant client et leur secret client lors de la création de connexions via la AWS Glue console. Dans ce scénario, ils seront toujours redirigés vers Zoom Meetings pour se connecter et autoriser AWS Glue l'accès à leurs ressources.
- Ce type de subvention donne lieu à un jeton d'actualisation et à un jeton d'accès. Le jeton d'accès est de courte durée et peut être actualisé automatiquement sans interaction de l'utilisateur à l'aide du jeton d'actualisation.
- Pour consulter la documentation publique de Zoom Meetings sur la création d'une application connectée pour le OAuth flux de code d'autorisation, voir [Utilisation de la OAuth version 2.0](#).

Pour configurer une connexion Zoom Meetings :

1. Dans AWS Secrets Manager, créez un secret avec les informations suivantes :
 - a. Pour l'application connectée gérée par le client, le secret doit contenir le secret du consommateur de l'application connectée avec `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` comme clé.
 - b. Remarque : vous devez créer un secret pour vos connexions dans AWS Glue.
1. Dans AWS Glue Glue Studio, créez une connexion sous Data Connections en suivant les étapes ci-dessous :
 - a. Lorsque vous sélectionnez un type de connexion, sélectionnez Zoom Meetings.
 - b. Indiquez l'environnement Zoom Meetings auquel vous souhaitez vous connecter.

- c. Sélectionnez le rôle AWS IAM qui AWS Glue peut assumer et dispose des autorisations nécessaires pour les actions suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterface",
        "ec2:DeleteNetworkInterface",
      ],
      "Resource": "*"
    }
  ]
}
```

- d. Sélectionnez celui `secretName` que vous souhaitez utiliser pour cette connexion AWS Glue afin d'y placer les jetons.
- e. Sélectionnez les options réseau si vous souhaitez utiliser votre réseau.
2. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire `secretName`.

Lecture depuis les entités de Zoom Meetings

Prérequis

Un objet Zoom Meetings dont vous souhaitez lire un extrait. Vous aurez besoin du nom de l'objet tel que `Group` ou `Zoom Rooms`.

Entités prises en charge pour la source :

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Zoom Rooms	Non	Oui	Non	Oui	Non

Entité	Peut être filtré	Limite de supports	Supporte Order by	Supporte Select *	Supporte le partitionnement
Groupe	Non	Non	Non	Oui	Non
Membre du groupe	Oui	Oui	Non	Oui	Non
Administrateur du groupe	Non	Oui	Non	Oui	Non
Rapport (quotidien)	Oui	Non	Non	Oui	Non
Rôles	Non	Non	Non	Oui	Non
Users	Oui	Oui	Non	Oui	Non

Exemple :

```
zoom_read = glueContext.create_dynamic_frame.from_options(
    connection_type="zoom",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "organization",
        "API_VERSION": "v2"
    }
)
```

Détails de l'entité et du champ Zoom Meetings :

Zoom Meetings charge dynamiquement les champs disponibles sous l'entité sélectionnée. Selon le type de données du champ, il prend en charge les opérateurs de filtre suivants.

Entité	Champ	Type de données	Opérateurs pris en charge	
Chambre Zoom	status	Chaîne	=	
	type	Chaîne	=	
	chambres_non assignées	Booléen	=	
	identifiant_lieu	Chaîne	=	
	ID de la chambre	Chaîne	N/A	
	code d'activation	Chaîne	N/A	
	id	Chaîne	N/A	
	name	Chaîne	N/A	
	identifiant_tags	Chaîne	N/A	
	query_name	Chaîne	N/A	
Rapport quotidien	month	Date	=	
	date	Date	N/A	
	minutes de réunion	Entier	N/A	
	réunions	Entier	N/A	
	nouvelles_utilisateurs	Entier	N/A	
	participants	Entier	N/A	
	group_id	Chaîne	N/A	
Utilisateur	created_at	DateTime	N/A	

Entité	Champ	Type de données	Opérateurs pris en charge	
	département	Chaîne	N/A	
	e-mail	Chaîne	N/A	
	identifiant_unique_employé	Chaîne	N/A	
	first_name	Chaîne	N/A	
	identifiant_groupes	Liste	N/A	
	clé_hôte	Chaîne	N/A	
	id	Chaîne	N/A	
	im_group_ids	Chaîne	N/A	
	dernière_version_client	Chaîne	N/A	
	last_login_time	DateTime	N/A	
	last_name	Chaîne	N/A	
	plan_unité_type	Chaîne	N/A	
	attributs_personnalisés	Liste	N/A	
	pmi	BigInteger	N/A	
	role_id	Chaîne	=	
	status	Chaîne	=	
	timezone	Chaîne	N/A	

Entité	Champ	Type de données	Opérateurs pris en charge	
	type	Entier	N/A	
	verified	Entier	N/A	
	user_created_at	DateTime	N/A	
	display_name	Chaîne	N/A	
	phone_number	Chaîne	N/A	
	langage	Chaîne	N/A	
	licence	Chaîne	=	
Groupe	id	Chaîne	N/A	
	name	Chaîne	N/A	
	nombre total de membres	Entier	N/A	
Membre du groupe	e-mail	Chaîne	N/A	
	first_name	Chaîne	N/A	
	id	Chaîne	N/A	
	last_name	Chaîne	N/A	
	type	Entier	N/A	
	groupe_primaire	Booléen	N/A	
	identifiant_membre	Chaîne	N/A	
Administrateur du groupe	id	Chaîne	N/A	
	e-mail	Chaîne	N/A	

Entité	Champ	Type de données	Opérateurs pris en charge	
	name	Chaîne	N/A	
rôle	description	Chaîne	N/A	
	id	Chaîne	N/A	
	name	Chaîne	N/A	
	nombre total de membres	Entier	N/A	
	type	Chaîne	=	

Requêtes de partitionnement

Zoom Meetings ne prend pas en charge le partitionnement basé sur des filtres ou le partitionnement basé sur des enregistrements.

Options de connexion de Zoom Meetings

Les options de connexion pour Zoom Meetings sont les suivantes :

- **ENTITY_NAME**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Nom de l'entité Zoom Meetings. Par exemple, group.
- **API_VERSION**(Chaîne) - (Obligatoire) Utilisé pour la lecture. Version de l'API Rest de Zoom Meetings que vous souhaitez utiliser. La valeur sera v2, car Zoom Meetings ne prend actuellement en charge que la version v2.
- **SELECTED_FIELDS**(Liste<String>) - Par défaut : vide (SELECT *). Utilisé pour la lecture. Liste de colonnes séparées par des virgules que vous souhaitez sélectionner pour l'entité sélectionnée.
- **FILTER_PREDICATE**(String) - Par défaut : vide. Utilisé pour la lecture. Il doit être au format Spark SQL.
- **QUERY**(String) - Par défaut : vide. Utilisé pour la lecture. Requête SQL Spark complète.

Limites de Zoom Meetings

Les restrictions ou remarques suivantes concernent les réunions Zoom :

- Zoom Meetings ne prend pas en charge la commande par ordre.
- Zoom Meetings ne prend pas en charge le partitionnement basé sur des filtres car aucun champ ne peut répondre aux critères requis.
- Zoom Meetings ne prend pas en charge le partitionnement basé sur les enregistrements car la limite de pagination et la pagination basée sur le décalage ne sont pas prises en charge.

Ajout d'une connexion JDBC à l'aide de vos propres pilotes JDBC

Vous pouvez utiliser votre propre pilote JDBC lorsque vous utilisez une connexion JDBC. Lorsque le pilote par défaut utilisé par le AWS Glue robot d'exploration ne parvient pas à se connecter à une base de données, vous pouvez utiliser votre propre pilote JDBC. Par exemple, si vous souhaitez utiliser SHA-256 avec votre base de données Postgres et que les anciens pilotes Postgres ne le prennent pas en charge, vous pouvez utiliser votre propre pilote JDBC.

Sources de données prises en charge

Sources de données prises en charge	Sources de données non prises en charge
MySQL	Snowflake
Postgres	
Oracle	
Redshift	
SQL Server	
Aurora*	

* Pris en charge si le pilote JDBC natif est utilisé. Toutes les fonctionnalités du pilote ne peuvent pas être exploitées.

Ajout d'un pilote JDBC à une connexion JDBC

Note

Si vous choisissez d'utiliser vos propres versions de pilote JDBC, les robots d' AWS Glue exploration consommeront des ressources dans les AWS Glue tâches et les compartiments Amazon S3 pour s'assurer que le pilote fourni est exécuté dans votre environnement. L'utilisation supplémentaire des ressources sera reflétée sur votre compte. Le coût des AWS Glue robots d'exploration et des tâches figure dans la AWS Glue catégorie indiquée dans la facturation. De plus, le fait de fournir votre propre pilote JDBC ne signifie pas que le Crawler est capable de tirer parti de toutes les fonctionnalités du pilote.

Pour ajouter votre propre pilote JDBC à une connexion JDBC :

1. Ajoutez le fichier du pilote JDBC à un emplacement Amazon S3. Vous pouvez créer un and/or folder or use an existing bucket and/or dossier de compartiments.
2. Dans la AWS Glue console, choisissez Connexions dans le menu de gauche sous Catalogue de données, puis créez une nouvelle connexion.
3. Complétez les champs pour Propriétés de connexion et choisissez JDBC pour Type de connexion.
4. Dans Accès à la connexion, entrez l'URL JDBC et le nom de la classe de pilote JDBC (facultatif). Le nom de classe du pilote doit être celui d'une source de données prise en charge par les robots d' AWS Glue exploration.

Connection access

JDBC URL

Use the JDBC protocol to access Amazon Redshift, Amazon RDS, and publicly accessible databases.

JDBC syntax for most database engines is `jdbc:protocol://host:port/databasename`.

JDBC Driver Class name - *optional*

Type a custom JDBC driver class name for the crawler to connect to the data source.

JDBC Driver S3 Path - *optional*

✕ View Browse S3

Browse for or enter an existing S3 path to a .jar file.

Please note that if you choose to bring in your own JDBC driver versions to be used with Glue Crawlers, the Glue Crawlers will consume resources in Glue Jobs and S3 to ensure your provided driver are run in your environment. The additional usage of resources will be reflected in your account.

Credential type

☒ Username and password

☐ Secret

Username

Password

5. Choisissez le chemin Amazon S3 où se trouve le pilote JDBC dans chemin Amazon S3 du pilote JDBC : champ (facultatif).
6. Complétez les champs du type d'informations d'identification si vous saisissez un nom d'utilisateur et un mot de passe ou un code secret. Lorsque vous avez terminé, choisissez Créer une connexion.

Note

Le test de connexion n'est pas pris en charge pour le moment. Lorsque vous effectuez une indexation de site web de la source de données à l'aide d'un pilote JDBC que vous avez fourni, le Crawler ignore cette étape.

7. Ajoutez la connexion nouvellement créée à un Crawler. Dans la AWS Glue console, choisissez Crawlers dans le menu de gauche sous Data Catalog, puis créez un nouveau crawler.
8. Dans l'assistant Ajouter un Crawler, à l'étape 2, choisissez Ajouter une source de données.

Add data source ✕

Data source
Choose the source of data to be crawled.

JDBC ▼

Connection
Select a connection to access the data sources below.

mysql-connection068fd134-c2f1-4234-ad6b-345968e73be8 ▼ ↻

Clear selection Add new connection [↗](#)

Include path

public/%

You can substitute the percent (%) character for a schema or table. For databases that support schemas, enter MyDatabase/MySchema/% to match all tables in MySchema within MyDatabase. Oracle Database and MySQL don't support schema in the path; instead, enter MyDatabase/%. For Oracle database without SSL, MyDatabase can be either the system identifier (SID) or the service name (SERVICE_NAME). For Oracle database with SSL, MyDatabase must be the service name (SERVICE_NAME).

Additional metadata - optional

▼

Select additional metadata properties for the crawler to crawl.

☐ Exclude tables matching pattern

Cancel Add a JDBC data source

9. Choisissez JDBC comme source de données et choisissez la connexion créée lors des étapes précédentes. Complet
10. Pour utiliser votre propre pilote JDBC avec un AWS Glue robot d'exploration, ajoutez les autorisations suivantes au rôle utilisé par le robot d'exploration :

- Accordez des autorisations pour les actions de tâches suivantes : `CreateJob`, `DeleteJob`, `GetJob`, `GetJobRun`, `StartJobRun`.
- Accordez des autorisations pour les actions IAM : `iam:PassRole`
- Accordez des autorisations pour les actions Amazon S3 : `s3:DeleteObjects`, `s3:GetObject`, `s3:ListBucket`, `s3:PutObject`.
- Accordez au principal de service l'accès au compartiment ou au dossier dans la politique IAM.

Exemple de politique IAM :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "VisualEditor0",
      "Effect": "Allow",
      "Action": [
        "s3:PutObject",
        "s3:GetObject",
        "s3:ListBucket",
        "s3:DeleteObject"
      ],
      "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket/driver-parent-folder/driver.jar",
        "arn:aws:s3:::amzn-s3-demo-bucket"
      ]
    }
  ]
}
```

Le AWS Glue robot crée deux dossiers : `_glue_job_crawler` et `_crawler`.

Si le fichier JAR du pilote se trouve dans le `s3://amzn-s3-demo-bucket/driver.jar` dossier, ajoutez les ressources suivantes :

```
"Resource": [
  "arn:aws:s3:::amzn-s3-demo-bucket/_glue_job_crawler/*",
  "arn:aws:s3:::amzn-s3-demo-bucket/_crawler/*"
]
```

Si le fichier JAR du pilote se trouve dans le `s3://amzn-s3-demo-bucket/tmp/driver/subfolder/driver.jar` dossier, ajoutez les ressources suivantes :

```
"Resource": [
    "arn:aws:s3:::amzn-s3-demo-bucket/tmp/_glue_job_crawler/*",
    "arn:aws:s3:::amzn-s3-demo-bucket/tmp/_crawler/*"
]
```

11. Si vous utilisez un VPC, vous devez autoriser l'accès au point de AWS Glue terminaison en créant le point de terminaison de l'interface et en l'ajoutant à votre table de routage. Pour plus d'informations, consultez [Création d'un point de terminaison VPC d'interface](#) pour AWS Glue
12. Si vous utilisez le chiffrement dans votre catalogue de données, créez le point de terminaison de l' AWS KMS interface et ajoutez-le à votre table de routage. Pour de plus amples informations, consultez [Creating a VPC endpoint for AWS KMS](#).

Utilisation de connecteurs personnalisés et de connexions avec AWS Glue Studio

AWS Glue fournit un support intégré pour les magasins de données les plus couramment utilisés (tels qu'Amazon Aurora Amazon Redshift, Microsoft SQL Server, MySQL, MongoDB et PostgreSQL) à l'aide de connexions JDBC. AWS Glue vous permet également d'utiliser des pilotes JDBC personnalisés dans vos tâches d'extraction, de transformation et de chargement (ETL). Pour les magasins de données qui ne sont pas pris en charge en mode natif, comme les applications SaaS, vous pouvez utiliser des connecteurs.

Un connecteur est un package de code facultatif qui facilite l'accès aux magasins de données dans AWS Glue Studio. Vous pouvez vous abonner à plusieurs connecteurs proposés dans AWS Marketplace.

Lorsque vous créez des tâches ETL, vous pouvez utiliser un magasin de données pris en charge de manière native AWS Marketplace, un connecteur ou vos propres connecteurs personnalisés. Si vous utilisez un connecteur, vous devez d'abord créer une connexion pour le connecteur. Une connexion contient les propriétés requises pour se connecter à un magasin de données particulier. Vous utilisez la connexion avec vos sources de données et cibles de données dans la tâche ETL. Les connecteurs et les connexions fonctionnent ensemble pour faciliter l'accès aux magasins de données.

Les connexions suivantes sont disponibles lors de la création de connexions pour les connecteurs :

- Amazon Aurora: un moteur de base de données relationnelle évolutif et très performant doté de fonctionnalités intégrées de sécurité, de sauvegarde et de restauration, ainsi que d'accélération en mémoire.
- Amazon DocumentDB : un service de base de données de documents évolutif, hautement disponible et entièrement géré qui prend en charge MongoDB et SQL. APIs
- Amazon Redshift: un service de base de données de documents évolutif, hautement disponible et entièrement géré qui prend en charge MongoDB et SQL. APIs
- Azure SQL : un service de base de données relationnelle basé sur le cloud de Microsoft Azure qui fournit des fonctionnalités de stockage et de gestion de données évolutives, fiables et sécurisées.
- Cosmos DB : un service de base de données basé sur le cloud distribué dans le monde entier de Microsoft Azure qui fournit des fonctionnalités de stockage et de requête de données évolutives et très performantes.
- Google BigQuery : un entrepôt de données cloud sans serveur permettant d'exécuter des requêtes SQL rapides sur de grands ensembles de données.
- JDBC : système de gestion de base de données relationnelle (RDBMS) qui utilise une API Java pour se connecter et interagir avec les connexions de données.
- Kafka : une plateforme de traitement de flux open source utilisée pour le streaming de données et la messagerie en temps réel.
- MariaDB : une fourche développée par la communauté de MySQL qui offre des performances, une évolutivité et des fonctionnalités améliorées.
- MongoDB : une base de données multiplateforme orientée documents qui offre une évolutivité, une flexibilité et des performances élevées.
- MongoDB Atlas : une offre de base de données en tant que service (DBaaS) basée sur le cloud de MongoDB qui simplifie la gestion et le dimensionnement des déploiements MongoDB.
- Microsoft SQL Server : système de gestion de base de données relationnelle (RDBMS) de Microsoft qui fournit des fonctionnalités robustes de stockage, d'analyse et de création de rapports.
- Mixpanel : plate-forme d'analyse qui aide les entreprises à analyser la manière dont les utilisateurs interagissent avec leurs sites Web, leurs applications mobiles et leurs autres produits numériques.
- MySQL : un système de gestion de base de données relationnelle (RDBMS) open source largement utilisé dans les applications web et connu pour sa fiabilité et sa capacité de mise à l'échelle.

- Réseau : une source de données réseau représente une ressource ou un service accessible par le réseau auquel une plateforme d'intégration de données peut accéder.
- OpenSearch— une source de OpenSearch données est une application qui OpenSearch peut se connecter à des données et les ingérer depuis.
- Oracle : un système de gestion de base de données relationnelle (RDBMS) d'Oracle Corporation qui fournit des fonctionnalités robustes de stockage, d'analyse et de création de rapports.
- PostgreSQL : un système de gestion de base de données relationnelle (RDBMS) open source qui fournit des fonctionnalités robustes de stockage, d'analyse et de création de rapports.
- Salesforce — Salesforce fournit un logiciel de gestion de la relation client (CRM) qui vous aide dans les domaines des ventes, du service client, du commerce électronique, etc. Si vous êtes un utilisateur de Salesforce, vous pouvez vous connecter AWS Glue à votre compte Salesforce. Vous pouvez ensuite utiliser Salesforce comme source de données ou destination dans vos tâches ETL. Exécutez ces tâches pour transférer des données entre Salesforce et les AWS services ou d'autres applications prises en charge.
- SAP HANA : une base de données en mémoire et plateforme d'analyse qui permet un traitement rapide des données, des analyses avancées et une intégration des données en temps réel.
- Snowflake : un entrepôt des données basé sur le cloud qui fournit des services d'analyse et de stockage de données évolutifs et très performants.
- Teradata : un système de gestion de base de données relationnelle (RDBMS) qui fournit des fonctionnalités très performantes de stockage, d'analyse et de création de rapports.
- Vertica : un entrepôt des données analytiques orienté colonnes conçu pour l'analytique du big data qui offre des performances de requêtes rapides, des analyses avancées et capacité de mise à l'échelle.

Création de connecteurs personnalisés

Vous pouvez également créer votre propre connecteur, puis télécharger le code du connecteur sur AWS Glue Studio.

Des connecteurs personnalisés sont intégrés dans AWS Glue Studio par le biais du AWS Glue API d'exécution Spark. Le AWS Glue Le runtime Spark vous permet de brancher n'importe quel connecteur compatible avec l'interface Spark, Athena ou JDBC. Cela vous permet de transférer n'importe quelle option de connexion disponible avec le connecteur personnalisé.

Vous pouvez encapsuler toutes vos propriétés de connexion avec [AWS Glue Connexions](#) et fournissez le nom de connexion à votre tâche ETL. L'intégration aux connexions Data Catalog vous

permet d'utiliser les mêmes propriétés de connexion sur plusieurs appels dans une seule application Spark ou différentes applications.

Vous pouvez spécifier des options supplémentaires pour la connexion. Le script de tâche qui AWS Glue Studio generate contient une Datasource entrée qui utilise la connexion pour brancher votre connecteur avec les options de connexion spécifiées. Par exemple :

```
Datasource = glueContext.create_dynamic_frame.from_options(connection_type =  
"custom.jdbc", connection_options = {"dbTable":"Account","connectionName":"my-custom-  
jdbc-  
connection"}, transformation_ctx = "DataSource0")
```

Pour ajouter un connecteur personnalisé à AWS Glue Studio

1. Créez le code de votre connecteur personnalisé. Pour de plus amples informations, veuillez consulter [Développement de connecteurs personnalisés](#).
2. Ajouter un support pour AWS Glue fonctionnalités de votre connecteur. Voici quelques exemples de ces fonctionnalités et de la façon dont elles sont utilisées dans le script de tâche généré par AWS Glue Studio:
 - Mappage des types de données : votre connecteur peut convertir les colonnes tout en les lisant à partir du magasin de données sous-jacent. Par exemple, un `dataTypeMapping` de `{"INTEGER":"STRING"}` convertit toutes les colonnes de type `Integer` en colonnes de type `String` lors de l'analyse des enregistrements et de la création du fichier `DynamicFrame`. Cela aide les utilisateurs à convertir les colonnes en types de leur choix.

```
DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type  
= "custom.jdbc", connection_options = {"dataTypeMapping":{"INTEGER":"STRING"},  
connectionName":"test-connection-jdbc"}, transformation_ctx = "DataSource0")
```

- Partitionnement pour les lectures parallèles — AWS Glue permet la lecture parallèle des données depuis le magasin de données en partitionnant les données sur une colonne. Vous devez spécifier la colonne de partition, la limite de partition inférieure, la limite de partition supérieure et le nombre de partitions. Cette fonction vous permet d'utiliser à la fois le parallélisme des données et plusieurs exécuteurs Spark alloués à l'application Spark.

```
DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type  
= "custom.jdbc", connection_options = {"upperBound":"200","numPartitions":"4",  
"partitionColumn":"id","lowerBound":"0","connectionName":"test-connection-jdbc"},
```

```
transformation_ctx = "DataSource0")
```

- **AWS Secrets Manager** À utiliser pour stocker les informations d'identification : la connexion au catalogue de données peut également contenir un `secretId` code secret stocké dans AWS Secrets Manager. Le AWS secret peut stocker en toute sécurité les informations d'authentification et d'identification et les fournir AWS Glue lors de l'exécution. Vous pouvez également spécifier le `secretId` à partir du script Spark comme suit :

```
DataSource = glueContext.create_dynamic_frame.from_options(connection_type =  
    "custom.jdbc", connection_options = {"connectionName":"test-connection-jdbc",  
    "secretId"-> "my-secret-id"}, transformation_ctx = "DataSource0")
```

- **Filtrer les données sources à l'aide de prédicats de lignes et de projections de colonnes** — Le AWS Glue L'environnement d'exécution Spark permet également aux utilisateurs d'envoyer des requêtes SQL vers le bas afin de filtrer les données à la source à l'aide de prédicats de lignes et de projections de colonnes. Cela permet à votre tâche ETL de charger plus rapidement les données filtrées à partir des magasins de données qui prennent en charge les transferts. Voici un exemple de requête SQL transmise à une source de données JDBC :
`SELECT id, name, department FROM department WHERE id < 200.`

```
DataSource = glueContext.create_dynamic_frame.from_options(connection_type =  
    "custom.jdbc", connection_options = {"query":"SELECT id, name, department FROM  
    department  
    WHERE id < 200", "connectionName":"test-connection-jdbc"}, transformation_ctx =  
    "DataSource0")
```

- **Favoris pour les offres d'emploi** — AWS Glue prend en charge le chargement incrémentiel de données à partir de sources JDBC. AWS Glue assure le suivi du dernier enregistrement traité depuis le magasin de données et traite les nouveaux enregistrements de données lors des exécutions de tâches ETL suivantes. Les marque-pages de tâche utilisent la clé primaire comme colonne par défaut pour la clé de marque-page, à condition que cette colonne augmente ou diminue de manière séquentielle. Pour plus d'informations sur les marque-pages de tâche, consultez [Marque-pages de tâche](#) dans le Guide du développeur AWS Glue .

```
DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type =  
    "custom.jdbc", connection_options = {"jobBookmarkKeys":["empno"],  
    "jobBookmarkKeysSortOrder"  
    :"asc", "connectionName":"test-connection-jdbc"}, transformation_ctx =  
    "DataSource0")
```

3. Embaquetez le connecteur personnalisé en tant que fichier JAR et téléchargez le fichier sur Amazon S3.
4. Testez votre connecteur personnalisé. Pour plus d'informations, consultez les instructions sur GitHub at [Glue Custom Connectors : Local Validation Tests Guide](#).
5. Dans le volet AWS Glue Studio console, choisissez Connectors dans le volet de navigation de la console.
6. Sur la page Connectors (Connecteurs), sélectionnez Create custom connector (Créer un connecteur personnalisé).
7. Sur la page Create custom connector (Créer un connecteur personnalisé), saisissez les informations suivantes :
 - Chemin d'accès à l'emplacement du fichier JAR de code personnalisé dans Amazon S3.
 - Nom du connecteur qui sera utilisé par AWS Glue Studio.
 - Votre type de connecteur, JDBC, Spark ou Athena.
 - Le nom du point d'entrée dans votre code personnalisé qui AWS Glue Studio appelle pour utiliser le connecteur.
 - Pour les connecteurs JDBC, ce champ doit être le nom de classe de votre pilote JDBC.
 - Pour les connecteurs Spark, ce champ doit être le nom complet de la classe de source de données, ou son alias, que vous utilisez lors du chargement de la source de données Spark avec l'opérateur format.
 - (JDBC uniquement) URL de base utilisée par la connexion JDBC pour le magasin de données.
 - (Facultatif) Description du connecteur personnalisé.
8. Sélectionnez Create connector (Créer un connecteur).
9. Depuis la page Connectors (Connecteurs), créez une connexion qui utilise ce connecteur, comme décrit dans [Création de connexions pour les connecteurs](#).

Ajouter des connecteurs à AWS Glue Studio

Un connecteur est un bout de code qui facilite la communication entre votre magasin de données et AWS Glue. Vous pouvez soit vous abonner à un connecteur proposé dans AWS Marketplace, soit créer votre propre connecteur personnalisé.

Abonnement à des connecteurs AWS Marketplace

AWS Glue Studio permet d'ajouter facilement des connecteurs à partir de AWS Marketplace.

Pour ajouter un connecteur de AWS Marketplace à AWS Glue Studio

1. Dans le volet AWS Glue Studio console, choisissez Connectors dans le volet de navigation de la console.
2. Sur la page Connectors (Connecteurs), sélectionnez Go to AWS Marketplace (Accéder à MKT).
3. Dans AWS Marketplace, dans Produits en vedette, choisissez le connecteur que vous souhaitez utiliser. Vous pouvez choisir l'un des connecteurs disponibles ou utiliser la recherche. Vous pouvez effectuer une recherche sur le nom ou le type de connecteur, et utiliser des options pour affiner les résultats de cette recherche.

Si vous souhaitez utiliser l'un des connecteurs proposés, sélectionnez View product (Afficher le produit). Si vous avez utilisé la recherche pour localiser un connecteur, choisissez le nom de celui-ci.

4. Sur la page produit du connecteur, utilisez les onglets pour afficher des informations sur le connecteur. Si vous décidez d'acheter ce connecteur, sélectionnez Continue to Subscribe (Continuer pour s'abonner).
5. Fournissez les informations de paiement, puis sélectionnez Continue to Configure (Continuer pour configurer).
6. Sur la page Configure this software (Configurer ce logiciel), choisissez la méthode de déploiement et la version du connecteur à utiliser. Puis sélectionnez Continue to Launch (Continuer pour lancer).
7. Sur la page Launch this software (Lancer ce logiciel), vous pouvez consulter les instructions d'utilisation fournies par le fournisseur du connecteur. Lorsque vous êtes prêt à continuer, choisissez Activer la connexion dans AWS Glue Studio.

Après un court laps de temps, la console affiche la page Créer une connexion au marché dans AWS Glue Studio.

8. Créez une connexion qui utilise ce connecteur, comme décrit dans [Création de connexions pour les connecteurs](#).

Vous pouvez également sélectionner Activate connector only (Activer le connecteur uniquement) pour ignorer la création d'une connexion à ce stade. Vous devez créer une connexion à une date ultérieure avant de pouvoir utiliser le connecteur.

Création de connexions pour les connecteurs

Une AWS Glue connexion est un objet du catalogue de données qui stocke les informations de connexion pour un magasin de données spécifique. Les connexions stockent les informations d'identification de connexion, les chaînes d'URI, les informations du virtual private cloud (VPC), etc. La création de connexions dans le catalogue de données permet d'éviter de spécifier tous les détails de connexion chaque fois que vous créez une tâche.


Pour créer une connexion pour un connecteur

1. Dans la AWS Glue Studio console, choisissez Connectors dans le volet de navigation de la console. Dans la section Connexions, choisissez Créer une connexion.
2. Choisissez la source de données pour laquelle vous souhaitez créer une connexion dans la première étape de l'assistant Créer une connexion de données. Il existe plusieurs façons de visualiser les sources de données disponibles, notamment :
 - Filtrez les sources de données disponibles en choisissant un onglet. Par défaut, Tous les connecteurs est sélectionné.
 - Basculez vers Liste pour afficher les sources de données sous forme de liste ou revenez à la Grille pour afficher les connecteurs disponibles dans la disposition en grille.
 - Utilisez la barre de recherche pour affiner la liste des sources de données. Lorsque vous tapez, les résultats de recherche s'affichent et les sources non correspondantes sont supprimées de la vue.

Une fois que vous avez choisi la source de données, choisissez Suivant.

3. Configurez la connexion dans la deuxième étape de l'assistant.

Saisissez les informations de connexion. Selon le type de connecteur que vous avez sélectionné, vous êtes invité à saisir des informations supplémentaires :



Connections (12) [Info](#) Actions ▼ Create connection Create job

You can manage your connections or use a connection in a job.


< 1 2 >

	Name ▼	Type ▼	Last modified ▼
☐	test-redshift	JDBC	Jun 23, 2023
☐	snowflake test	SNOWFLAKE	Jun 21, 2023
☐	gluestudio-dw-connection	JDBC	Jan 19, 2023
☐	API-calls-work-in-PDX	JDBC	Oct 24, 2022
☐	CUSTOM_JDBC_CERT_STRING	JDBC	Apr 28, 2022
☐	mongodb-connector	MongoDB	Apr 28, 2022
☐	kafka-test-1	KAFKA	Apr 13, 2022
☐	kafka-sasl-confirm	KAFKA	Apr 08, 2022
☐	kafka-sasl-test	KAFKA	Apr 08, 2022
☐	test-connection-4-21-21	JDBC	Apr 21, 2021

4. Choisissez la source de données pour laquelle vous souhaitez créer une connexion dans la première étape de l'assistant Créer une connexion de données. Il existe plusieurs méthodes pour afficher les sources de données disponibles. Par défaut, vous verrez toutes les sources de données disponibles sous forme de grille. Vous pouvez également :

- Basculez vers Liste pour afficher les sources de données sous forme de liste ou revenez à la Grille pour afficher les connecteurs disponibles dans la disposition en grille.
- Utilisez la barre de recherche pour affiner la liste des sources de données. Lorsque vous tapez, les résultats de recherche s'affichent et les sources non correspondantes sont supprimées de la vue.

Choose data source



Data sources (21) Grid List

Une fois que vous avez choisi la source de données, choisissez Suivant.

5. Configurez la connexion dans la deuxième étape de l'assistant.

Saisissez les informations de connexion. Selon le type de connecteur que vous avez sélectionné, vous devrez peut-être saisir des informations de connexion supplémentaires. Cela peut inclure :

- **Détails de connexion** : ces champs changeront en fonction de la source de données à laquelle vous vous connectez. Par exemple, si vous vous connectez aux bases de données Amazon DocumentDB, vous devez saisir l'URL Amazon DocumentDB. Si vous vous connectez à Amazon Aurora, vous devez choisir l'instance de base de données et entrer le nom de la base de données. Voici les détails de connexion requis pour Amazon Aurora :

The screenshot shows the 'Configure connection' step in the AWS Glue console. On the left, a sidebar lists four steps: Step 1 (Choose data source), Step 2 (Configure connection - currently active), Step 3 (Set properties), and Step 4 (Review and create). The main area is titled 'Configure connection' and contains a 'Connection details' section. This section includes a 'Database instances' dropdown menu with the text 'Choose one JDBC URL' and a refresh button. Below this is a 'Database name' text input field. The 'Credential type' section has two radio buttons: 'Username and password' (selected) and 'AWS Secrets Manager'. Under 'Username and password', there are text input fields for 'Username' and 'Password'. At the bottom right of the form are three buttons: 'Cancel', 'Previous', and 'Next'.

- **Type d'informations d'identification** : choisissez le nom d'utilisateur et mot de passe ou AWS Secrets Manager. Saisissez les informations d'authentification demandées.
 - Pour les connecteurs qui utilisent JDBC, entrez les informations requises pour créer l'URL JDBC pour le magasin de données.
 - Si vous utilisez un Virtual Private Cloud (VPC), saisissez les informations réseau de votre VPC.
6. Définissez les propriétés de connexion dans la troisième étape de l'assistant. Vous pouvez ajouter une description et des balises en tant que partie facultative de cette étape. Le nom est obligatoire et est prérempli avec une valeur par défaut. Choisissez Suivant.
 7. Vérifiez la source, les détails et les propriétés de la connexion. Si vous devez apporter des modifications, choisissez Modifier pour l'étape de l'assistant. Lorsque vous avez terminé, choisissez Créer une connexion.

Choisissez Créer une connexion.

Vous revenez à la page Connectors (Connecteurs) et la bannière d'information indique la connexion qui a été créée. Vous pouvez maintenant utiliser la connexion dans vos tâches AWS Glue Studio .

Création d'une connexion Kafka

Lorsque vous créez une connexion Kafka, la sélection de Kafka dans le menu déroulant fait apparaître des paramètres supplémentaires à configurer :

- Détails du cluster Kafka
- Authentification
- Chiffrement
- Options réseau

Configurer les détails du cluster Kafka

1. Choisissez l'emplacement du cluster. Vous pouvez choisir parmi un cluster Streaming géré par Amazon pour Apache Kafka (MSK) (Amazon Managed Streaming for Apache Kafka (MSK)) ou un cluster Customer managed Apache Kafka (Apache Kafka géré par le client). Pour plus d'informations sur Amazon Managed Streaming pour Apache Kafka, consultez [Amazon Managed Streaming for Apache Kafka \(MSK\)](#).

Note

Amazon Managed Streaming for Apache Kafka prend uniquement en charge les méthodes d'authentification TLS et SASL/SCRAM-SHA-512.

Kafka cluster details [Info](#)

Cluster location

☐ Amazon managed streaming for Apache Kafka (MSK)

☒ Customer managed Apache Kafka

Kafka bootstrap server URLs [Info](#)

A comma-separated list of bootstrap server URLs. Include the port number.

Enter list of URLs, separated by commas

Example: b-1.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094, b-2.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094, b-3.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094

2. Entrez le URLs pour vos serveurs bootstrap Kafka. Vous pouvez en saisir plusieurs en séparant chaque serveur par une virgule. Incluez le numéro de port à la fin de l'URL en ajoutant :<port number>.

Par exemple : b-1.vpc-test-2.034a88o.kafka-us-east-1.amazonaws.com:9094

Sélection d'une méthode d'authentification

Authentication [Info](#)

Authentication method

Choose authentication method

AWS Glue prend en charge le framework SASL (Simple Authentication and Security Layer) pour l'authentification. Le framework SASL prend en charge divers mécanismes d'authentification et AWS Glue propose les protocoles SCRAM (nom d'utilisateur et mot de passe), GSSAPI (protocole Kerberos) et PLAIN (nom d'utilisateur et mot de passe).

Lorsque vous choisissez une méthode d'authentification dans le menu déroulant, les méthodes d'authentification client suivantes peuvent être sélectionnées :

- Aucune - Aucune authentification. Cette option est utile si vous créez une connexion pour des raisons de tests.
- SASL/SCRAM-SHA-512 - Choisissez cette méthode d'authentification pour spécifier les informations d'identification d'authentification. Deux options s'offrent à vous :
 - Utiliser AWS Secrets Manager (recommandé) : si vous sélectionnez cette option, vous pouvez enregistrer vos informations d'identification dans AWS Secrets Manager et autoriser l' AWS Glue accès aux informations en cas de besoin. Spécifiez le secret qui stocke les informations d'identification d'authentification SSL ou SASL.

The screenshot shows the 'Authentication' configuration page in AWS Glue. At the top, there's a title 'Authentication' with an 'Info' link. Below it, the 'Authentication method' is set to 'SASL/SCRAM-SHA-512' in a dropdown menu. Under 'Authentication credentials', the 'Use AWS Secrets Manager (recommended)' option is selected with a radio button. Below this, there's a description: 'Store your token in AWS Secrets Manager, and let AWS Glue access it when needed.' The other option, 'Provide username and password directly', is unselected. Below the radio buttons, it says 'Secret from' followed by a link to 'AWS Secrets Manager'. At the bottom, there's a search bar with the placeholder text 'Search secret by name or type ARN' and a refresh button.

- Entrez directement le nom d'utilisateur et le mot de passe.
- SASL/GSSAPI (Kerberos) - if you select this option, you can select the location of the keytab file, krb5.conf file and enter the Kerberos principal name and Kerberos service name. The locations for the keytab file and krb5.conf file must be in an Amazon S3 location. Since MSK does not yet support SASL/GSSAPI, cette option n'est disponible que pour les clusters Apache Kafka gérés par le client. Pour en savoir plus, consultez [MIT Kerberos Documentation: Keytab](#) (Documentation du MIT Kerberos : Keytab).
- SASL/PLAIN - Choisissez cette méthode d'authentification pour spécifier les informations d'authentification. Deux options s'offrent à vous :
 - Utiliser AWS Secrets Manager (recommandé) : si vous sélectionnez cette option, vous pouvez enregistrer vos informations d'identification dans AWS Secrets Manager et autoriser l' AWS Glue accès aux informations en cas de besoin. Spécifiez le secret qui stocke les informations d'identification d'authentification SSL ou SASL.

- Entrez directement le nom d'utilisateur et le mot de passe.
- Authentification client SSL : si vous sélectionnez cette option, vous pouvez sélectionner l'emplacement du centre de stockage des clés client Kafka en naviguant sur Amazon S3. Vous pouvez également entrer le mot de passe du centre de stockage des clés client Kafka et le mot de passe de la clé client Kafka.

The screenshot shows the 'Authentication' tab in the AWS Glue console. It features a dropdown menu for 'Authentication method' set to 'SSL client authentication'. Below this is a text field for 'Kafka client keystore location' containing 's3://bucket/prefix/object', with 'View' and 'Browse S3' buttons to its right. A note specifies the path format: 'Path must be in the form s3://bucket/prefix/path/. It must end with the file name and .jks extension.' Two optional password fields follow: 'Kafka client keystore password - optional' and 'Kafka client key password - optional', both with placeholder text 'Enter password'.

Configuration des paramètres de chiffrement


1. Si la connexion Kafka nécessite une connexion SSL, cochez la case correspondant à Require SSL connection (Connexion SSL obligatoire). Notez que la connexion échouera si elle ne parvient pas à se connecter via SSL. Le protocole SSL pour le chiffrement peut être utilisé avec n'importe quelle méthode d'authentification (SASL/SCRAM-SHA-512, SASL/GSSAPI, SASL/PLAIN ou authentification client SSL) et est facultatif.

Si la méthode d'authentification est paramétrée sur Authentification client SSL, cette option sera sélectionnée automatiquement et sera désactivée pour éviter toute modification.

2. (Facultatif). Choisissez l'emplacement du certificat privé auprès de l'autorité de certification (CA). Notez que l'emplacement de la certification doit se trouver dans un emplacement S3. Choisissez Browse (Parcourir) pour choisir le fichier dans un compartiment S3 connecté. Le chemin doit être

de la forme `s3://bucket/prefix/filename.pem`. Il doit se terminer par le nom du fichier et l'extension `.pem`.

- Vous pouvez choisir d'ignorer la validation d'un certificat auprès d'une autorité de certification (CA). Choisissez la case à cocher **Skip validation of certificate from certificate authority (CA)** (Sauter l'étape de validation du certificat de l'autorité de certification (CA)). Si cette case n'est pas cochée, AWS Glue valide les certificats pour trois algorithmes :
 - SHA256withRSA
 - SHA384withRSA
 - SHA512withRSA



Encryption [Info](#)

☒ **Require SSL connection**
The connection will fail if it's unable to connect over SSL.

Location of private certificate from certificate authority (CA) - *optional*

[View](#) [Browse S3](#)

Path must be in the form `s3://bucket/prefix/path/`. It must end with the file name and `.pem` extension.

☐ **Skip validation of certificate from certificate authority (CA)**
AWS Glue validates for three algorithms: SHA256withRSA, SHA384withRSA and SHA512withRSA.

(Facultatif) Options réseau

Les étapes suivantes sont facultatives pour configurer des groupes de VPC, de sous-réseau et de sécurité. Si votre AWS Glue tâche doit être exécutée sur des EC2 instances Amazon dans un sous-réseau de cloud privé virtuel (VPC), vous devez fournir des informations de configuration supplémentaires spécifiques au VPC.

- Choisissez le nom du cloud privé virtuel (VPC) qui contient votre sources de données.
- Choisissez le sous-réseau au sein de votre VPC.
- Choisissez un ou plusieurs groupes de sécurité qui autorisent l'accès au stockage des données dans votre sous-réseau VPC. Les groupes de sécurité sont associés à l'ENI attaché à votre sous-réseau. Vous devez choisir au moins un groupe de sécurité avec une règle entrante avec référencement automatique pour tous les ports TCP.

▼ Network options - *optional*

If your AWS Glue job needs to run on [Amazon Elastic Compute Cloud](#) (EC2) instances in a virtual private cloud (VPC) subnet, you must provide additional VPC-specific configuration information.

VPC [Info](#)

Choose the virtual private cloud that contains your data source.

Subnet [Info](#)

Choose the subnet within your VPC.

Security groups [Info](#)

Choose one or more security groups to allow access to the data store in your VPC subnet. Security groups are associated to the ENI attached to your subnet. You must choose at least one security group with a self-referencing inbound rule for all TCP ports.

Création de tâches avec des connecteurs personnalisés

Vous pouvez utiliser des connecteurs et des connexions pour les nœuds de source de données et les nœuds de cible de données dans AWS Glue Studio.

Rubriques

- [Créer des tâches qui utilisent un connecteur pour la source de données](#)
- [Configurer les propriétés source pour les nœuds qui utilisent des connecteurs](#)
- [Configurer les propriétés cibles pour les nœuds qui utilisent des connecteurs](#)

Créer des tâches qui utilisent un connecteur pour la source de données


Lorsque vous créez une tâche, vous pouvez choisir un connecteur pour la source de données et les cibles de données.

Pour créer une tâche qui utilise des connecteurs pour la source de données ou la cible de données

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue Studio console à <https://console.aws.amazon.com/gluestudio/>.

2. Depuis la page Connectors (Connecteurs), dans la liste de ressources Your connections (Vos connexions), choisissez la connexion que vous souhaitez utiliser dans votre tâche, puis sélectionnez Create job (Créer une tâche).

Sinon, sur le AWS Glue Studio Sur la page Tâches, sous Créer une tâche, choisissez Source et cible ajoutées au graphique. Dans la liste déroulante Source, choisissez le connecteur personnalisé que vous souhaitez utiliser dans votre tâche. Vous pouvez également sélectionner un connecteur pour Target (Cible).



3. Sélectionnez ensuite Create (Créer) pour ouvrir l'éditeur de tâches visuelles.
4. Configurez le nœud de source de données, comme décrit dans [Configurer les propriétés source pour les nœuds qui utilisent des connecteurs](#).
5. Continuez à créer votre tâche ETL en ajoutant des transformations, des magasins de données supplémentaires et des cibles de données, comme décrit dans [Démarrage de tâches Visual ETL dans AWS Glue Studio](#).
6. Personnalisez l'environnement d'exécution de la tâche en configurant les propriétés de la tâche comme décrit dans [Modifier les propriétés de tâche](#).

7. Enregistrez, puis exécutez la tâche.

Configurer les propriétés source pour les nœuds qui utilisent des connecteurs

Après avoir créé une tâche qui utilise un connecteur pour la source de données, l'éditeur de tâche visuelle affiche un graphique de tâche avec un nœud de source de données configuré pour le connecteur. Vous devez configurer les propriétés de la source de données pour ce nœud.

Pour configurer les propriétés d'un nœud de source de données qui utilise un connecteur

1. Choisissez le nœud de la source de données du connecteur dans le graphique de la tâche ou ajoutez un nouveau nœud et choisissez le connecteur pour le type de nœud. Ensuite, sur la droite, dans le panneau des détails du nœud, sélectionnez l'onglet Data source properties (Propriétés de la source de données), s'il n'est pas déjà sélectionné.

The screenshot displays the AWS Glue console interface for configuring a task named "Combine legislator data". The top navigation bar includes tabs for "Visual", "Script", "Job details", "Runs", and "Schedules". The "Visual" tab is active, showing a task graph with several nodes: "Data source - S3 bucket Memberships source ...", "Data source - S3 bucket Persons source table", "Transform - Join", "Data source - Connection Organizations table s...", "Transform - ApplyMapping Rename Org PK field", and "Transform - ApplyMapping Renamed keys for Join". The right-hand pane shows the "Node properties" for the "Data source properties - Connector" node. The "Connection" dropdown is set to "MyEsConn", and the "Schema" section is visible, indicating the schema editor is used to define the schema for the data source.

2. Sous l'onglet Data source properties (Propriétés de la source de données), choisissez la connexion que vous souhaitez utiliser pour cette tâche.

Saisissez les informations supplémentaires requises pour chaque type de connexion :

JDBC

- Type d'entrée de source de données : fournissez un nom de table ou une requête SQL comme source de données. Selon votre choix, vous devrez ensuite fournir les informations complémentaires suivantes :
 - Nom de la table : nom de la table dans la source de données. Si la source de données n'utilise pas le terme table, indiquez le nom d'une structure de données appropriée, comme indiqué par les informations d'utilisation du connecteur personnalisé (disponibles dans AWS Marketplace).
 - Prédicat de filtre : clause de condition à utiliser lors de la lecture de la source de données, similaire à une clause WHERE, qui est utilisée pour récupérer un sous-ensemble des données.
 - Code de requête : saisissez une requête SQL à utiliser pour récupérer un ensemble de données spécifique à partir de la source de données. Voici un exemple d'une requête SQL de base :

```
SELECT column_list FROM  
                                table_name WHERE where_clause
```

- Schéma : Parce que AWS Glue Studio utilise les informations stockées dans la connexion pour accéder à la source de données au lieu de récupérer les informations de métadonnées d'une table du catalogue de données. Vous devez fournir les métadonnées du schéma de la source de données. Sélectionnez Add schema (Ajouter un schéma) pour ouvrir l'éditeur de schéma.

Pour obtenir des instructions sur l'utilisation de l'éditeur de schéma, veuillez consulter [Modifier le schéma d'un nœud de transformation personnalisé](#).

- Colonne de partition : (facultatif) vous pouvez choisir de partitionner les lectures de données en fournissant des valeurs pour Partition column (Colonne de partition), Lower bound (Limite inférieure), Upper bound (Limite supérieure) et Number of partitions (Nombre de partitions).

Les valeurs `lowerBound` et `upperBound` sont utilisées pour décider de la progression de la partition, pas pour filtrer les lignes de la table. Toutes les lignes de la table sont partitionnées et renvoyées.

 Note

Le partitionnement de colonne ajoute une condition de partitionnement supplémentaire à la requête utilisée pour lire les données. Lorsque vous utilisez une requête au lieu d'un nom de table, vous devez valider que la requête fonctionne avec la condition de partitionnement spécifiée. Par exemple :

- Si le format de votre requête est `"SELECT col1 FROM table1"`, testez la requête en ajoutant une clause `WHERE` à la fin de la requête qui utilise la colonne de partition.
 - Si le format de votre requête est `"SELECT col1 FROM table1 WHERE col2=val"`, testez la requête en étendant la clause `WHERE` avec `AND` et une expression qui utilise la colonne de partition.
- Conversion de type de données : si la source de données utilise des types de données qui ne sont pas disponibles dans JDBC, utilisez cette section pour spécifier comment un type de données de la source de données doit être converti en types de données JDBC. Vous pouvez spécifier jusqu'à 50 conversions de types de données différents. Toutes les colonnes de la source de données qui utilisent le même type de données sont converties de la même manière.

Par exemple, si vous avez trois colonnes dans la source de données qui utilisent le type de données `Float` et que vous indiquez que le type de données `Float` doit être converti en type de données JDBC `String`, les trois colonnes qui utilisent le type de données `Float` sont converties en types de données `String`.

- Clés relatives aux favoris de tâches : aide aux favoris de tâches AWS Glue conserver les informations d'état et empêcher le retraitement des anciennes données. Spécifiez une ou plusieurs colonnes comme clés de signet. AWS Glue Studio utilise des touches de signet pour suivre les données qui ont déjà été traitées lors d'une exécution précédente de la tâche ETL. Toutes les colonnes que vous utilisez pour les clés de marque-page personnalisées doivent être croissantes ou décroissantes de manière monotonique et stricte, mais les espaces sont autorisés.

Si vous saisissez plusieurs clés de marque-page, elles sont combinées pour former une seule clé composée. Une clé de marque-page de tâche composée ne doit pas contenir de colonnes en double. Si vous ne spécifiez pas de clés de signet, AWS Glue Studio utilise par défaut la clé primaire comme clé de signet, à condition que la clé primaire augmente

ou diminue de manière séquentielle (sans interruption). Si la table n'a pas de clé primaire, mais que la propriété de marque-page de tâche est activée, vous devez fournir des clés de marque-page de tâche personnalisées. Sinon, la recherche des clés primaires à utiliser par défaut échouera et l'exécution du travail échouera.

- Ordre de tri des clés de marque-page de la tâche : indiquez si les valeurs clés augmentent ou diminuent de façon séquentielle.

Spark

- Schéma : Parce que AWS Glue Studio utilise les informations stockées dans la connexion pour accéder à la source de données au lieu de récupérer les informations de métadonnées d'une table du catalogue de données. Vous devez fournir les métadonnées du schéma de la source de données. Sélectionnez Add schema (Ajouter un schéma) pour ouvrir l'éditeur de schéma.

Pour obtenir des instructions sur l'utilisation de l'éditeur de schéma, veuillez consulter [Modifier le schéma d'un nœud de transformation personnalisé](#).

- Options de connexion : saisissez des paires clé-valeur supplémentaires si nécessaire pour fournir des informations ou des options de connexion supplémentaires. Par exemple, vous pouvez saisir un nom de base de données, un nom de table, un nom d'utilisateur et un mot de passe.

Par exemple, pour OpenSearch, vous entrez les paires clé-valeur suivantes, comme décrit dans : [the section called “ Tutoriel : Utilisation du AWS Glue connecteur pour Elasticsearch ”](#)

- es.net.http.auth.user : *username*
- es.net.http.auth.pass : *password*
- es.nodes : https://<*Elasticsearch endpoint*>
- es.port : 443
- path: <*Elasticsearch resource*>
- es.nodes.wan.only : true

Pour un exemple des options de connexion minimales à utiliser, consultez l'exemple de script de test [MinimalSparkConnectorTest.scala](#) on GitHub, qui indique les options de connexion que vous devez normalement fournir dans une connexion.

Athena

- Nom de la table : nom de la table dans la source de données. Si vous utilisez un connecteur pour lire les CloudWatch journaux d'Athena, vous devez entrer le nom de la table. `all_log_streams`
- Nom du schéma Athena : choisissez le schéma dans votre source de données Athena qui correspond à la base de données qui contient la table. Si vous utilisez un connecteur pour lire les CloudWatch journaux d'Athena, vous devez entrer un nom de schéma similaire à. `/aws/glue/name`
- Schéma : Parce que AWS Glue Studio utilise les informations stockées dans la connexion pour accéder à la source de données au lieu de récupérer les informations de métadonnées d'une table du catalogue de données. Vous devez fournir les métadonnées du schéma de la source de données. Sélectionnez Add schema (Ajouter un schéma) pour ouvrir l'éditeur de schéma.

Pour obtenir des instructions sur l'utilisation de l'éditeur de schéma, veuillez consulter [Modifier le schéma d'un nœud de transformation personnalisé](#).

- Options de connexion supplémentaires : saisissez des paires clé-valeur supplémentaires si nécessaire pour fournir des informations ou des options de connexion supplémentaires.

Pour un exemple, consultez le README .md fichier à l'adresse <https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/Athena>. Dans les étapes de ce document, l'exemple de code montre les options de connexion minimales requises, qui sont `tableName`, `schemaName` et `className`. L'exemple de code spécifie ces options dans le cadre de la variable `optionsMap`, mais vous pouvez les spécifier pour votre connexion, puis utiliser la connexion.

3. (Facultatif) Après avoir fourni les informations requises, vous pouvez afficher le schéma de données résultant pour votre source de données en choisissant l'onglet Output schema (Schéma de sortie) dans le panneau des détails du nœud. Le schéma affiché sur cet onglet est utilisé par tous les nœuds enfants que vous ajoutez au graphique de tâche.
4. (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de la source de données, vous pouvez prévisualiser le jeu de données à partir de votre source de données en sélectionnant l'onglet Data preview (Prévisualisation des données) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Il y a un coût associé à l'utilisation de cette fonction, et la facturation commence dès que vous fournissez le rôle IAM.

Configurer les propriétés cibles pour les nœuds qui utilisent des connecteurs

Si vous utilisez un connecteur pour le type de cible de données, vous devez configurer les propriétés du nœud de cible de données.

Pour configurer les propriétés d'un nœud de cible de données qui utilise un connecteur

1. Choisissez le nœud cible des données du connecteur dans le graphique de la tâche. Ensuite, sur la droite, dans le panneau des détails du nœud, sélectionnez l'onglet Data target properties (Propriétés de la cible de données), s'il n'est pas déjà sélectionné.
2. Dans Data target properties (Propriétés des cibles de données), choisissez la connexion à utiliser pour écrire sur la cible.

Saisissez les informations supplémentaires requises pour chaque type de connexion :

JDBC

- Connexion : choisissez la connexion à utiliser avec votre connecteur. Pour plus d'informations sur la création d'une connexion, consultez [Création de connexions pour les connecteurs](#).
- Nom de la table : nom de la table dans la cible de données. Si la cible de données n'utilise pas le terme table, indiquez le nom d'une structure de données appropriée, comme indiqué par les informations d'utilisation du connecteur personnalisé (disponibles dans AWS Marketplace).
- Taille de lot (facultatif) : saisissez le nombre de lignes ou d'enregistrements à insérer dans la table cible en une seule opération. La valeur par défaut est de 1 000 lignes.

Spark

- Connexion : choisissez la connexion à utiliser avec votre connecteur. Si vous n'avez pas créé de connexion auparavant, sélectionnez Create connection (Créer une connexion) pour en créer une. Pour plus d'informations sur la création d'une connexion, consultez [Création de connexions pour les connecteurs](#).
- Options de connexion : saisissez des paires clé-valeur supplémentaires si nécessaire pour fournir des informations ou des options de connexion supplémentaires. Vous pouvez saisir un nom de base de données, un nom de table, un nom d'utilisateur et un mot de passe.

Par exemple, pour OpenSearch, vous entrez les paires clé-valeur suivantes, comme décrit dans : [the section called “ Tutoriel : Utilisation du AWS Glue connecteur pour Elasticsearch ”](#)

- `es.net.http.auth.user` : *username*
- `es.net.http.auth.pass` : *password*
- `es.nodes` : `https://<Elasticsearch endpoint>`
- `es.port` : 443
- `path`: *<Elasticsearch resource>*
- `es.nodes.wan.only` : true

Pour un exemple des options de connexion minimales à utiliser, consultez l'exemple de script de test [MinimalSparkConnectorTest.scala](#) on GitHub, qui indique les options de connexion que vous devez normalement fournir dans une connexion.

3. Après avoir fourni les informations requises, vous pouvez afficher le schéma de données résultant pour votre source de données en choisissant l'onglet Output schema (Schéma de sortie) dans le panneau des détails du nœud.

Gestion des connecteurs et des connexions

Vous utilisez la page Connexions dans AWS Glue pour gérer vos connecteurs et vos connexions.

Rubriques

- [Affichage des détails du connecteur et de la connexion](#)
- [Modification des connecteurs et des connexions](#)
- [Suppression des connecteurs et des connexions](#)
- [Annuler un abonnement pour un connecteur](#)

Affichage des détails du connecteur et de la connexion

Vous pouvez afficher des informations récapitulatives sur vos connecteurs et connexions dans les tableaux de ressources Your connectors (Vos connecteurs) et Your connections (Vos connexions) sur la page Connectors (Connecteurs). Pour afficher les informations détaillées, procédez comme suit.

Pour afficher les détails des connecteurs ou des connexions

1. Dans le volet AWS Glue Studio console, choisissez Connectors dans le volet de navigation de la console.
2. Choisissez le connecteur ou la connexion dont vous souhaitez afficher les informations détaillées.
3. Sélectionnez Actions, puis View details (Afficher les détails) pour ouvrir la page de détail de ce connecteur ou de cette connexion.
4. Sur la page détaillée, vous pouvez choisir de Edit (Modifier) ou de Delete (Supprimer) le connecteur ou la connexion.
 - Pour les connecteurs, vous pouvez sélectionner Create connecton (Créer une connexion) pour créer une connexion qui utilise le connecteur.
 - Pour les connexions, vous pouvez sélectionner Create job (Créer une tâche) pour créer une tâche qui utilise la connexion.

Modification des connecteurs et des connexions

Vous utilisez la page Connectors (Connecteurs) pour modifier les informations stockées dans vos connecteurs et connexions.

Pour modifier un connecteur ou une connexion

1. Dans le volet AWS Glue Studio console, choisissez Connectors dans le volet de navigation de la console.
2. Sélectionnez le connecteur ou la connexion que vous souhaitez modifier.
3. Sélectionnez Actions, puis Edit (Modifier).

Vous pouvez également sélectionner View details (Afficher les détails) et sur la page des détails du connecteur ou de la connexion, vous pouvez sélectionner Edit (Modifier).

4. Sur la page Edit connector (Modifier le connecteur) ou Edit connection (Modifier la connexion), mettez à jour les informations, puis sélectionnez Save (Enregistrer).

Suppression des connecteurs et des connexions

Vous pouvez utiliser la page Connectors (Connecteurs) pour supprimer les connecteurs et les connexions. Si vous supprimez un connecteur, toutes les connexions créées pour ce connecteur doivent également être supprimées.

Pour retirer les connecteurs de AWS Glue Studio

1. Dans le volet AWS Glue Studio console, choisissez Connectors dans le volet de navigation de la console.
2. Sélectionnez le connecteur ou la connexion que vous souhaitez supprimer.
3. Sélectionnez Actions, puis sélectionnez Delete (Supprimer).

Vous pouvez également sélectionner View details (Afficher les détails), puis sur la page détaillée du connecteur ou de la connexion, vous pouvez sélectionner Delete (Supprimer).

4. Vérifiez que vous souhaitez supprimer le connecteur ou la connexion en saisissant **Delete**, puis sélectionnez Delete (Supprimer).

Lors de la suppression d'un connecteur, toutes les connexions créées pour celui-ci sont également supprimées.

Toutes les tâches qui utilisent une connexion supprimée ne fonctionneront plus. Vous pouvez modifier les tâches pour utiliser un autre magasin de données ou les supprimer. Pour plus d'informations sur la suppression d'une tâche, veuillez consulter [Supprimer une tâche](#).

Si vous supprimez un connecteur, cela n'annule pas l'abonnement au connecteur dans AWS Marketplace. Pour supprimer un abonnement à un connecteur supprimé, suivez les instructions de la rubrique [Annuler un abonnement pour un connecteur](#).

Annuler un abonnement pour un connecteur

Après avoir supprimé les connexions et le connecteur de AWS Glue Studio, vous pouvez annuler votre abonnement AWS Marketplace si vous n'avez plus besoin du connecteur.

Note

Si vous annulez votre abonnement à un connecteur, cela ne supprime pas le connecteur ou la connexion de votre compte. Toutes les tâches qui utilisent le connecteur et les connexions associées ne pourront plus utiliser le connecteur et échoueront.

Avant de vous désabonner ou de vous réabonner à un connecteur de AWS Marketplace, vous devez supprimer les connexions existantes et les connecteurs associés à ce AWS Marketplace produit.

Pour vous désabonner d'un connecteur dans AWS Marketplace

1. Connectez-vous à la AWS Marketplace console sur <https://console.aws.amazon.com/marketket>.
2. Sélectionnez Manage subscriptions (Gérer les abonnements).
3. Depuis la page Manage subscriptions (Gérer les abonnements), sélectionnez Manage (Gérer) en regard de l'abonnement au connecteur que vous souhaitez annuler.
4. Sélectionnez Actions, puis Cancel subscription (Annuler l'abonnement).
5. Cochez la case pour confirmer que les instances en cours d'exécution sont facturées sur votre compte, puis sélectionnez Yes, cancel subscription (Oui, annuler l'abonnement).

Développement de connecteurs personnalisés

Vous pouvez écrire le code qui lit ou écrit des données dans votre magasin de données et formater les données pour les utiliser avec AWS Glue Studio emplois. Vous pouvez créer des connecteurs pour les magasins de données Spark, Athena et JDBC. L'exemple de code publié sur GitHub fournit un aperçu des interfaces de base que vous devez implémenter.

Vous aurez besoin d'un environnement de développement local pour créer votre code de connecteur. Vous pouvez utiliser n'importe quel IDE ou même simplement un éditeur de ligne de commande pour écrire votre connecteur. Voici quelques exemples d'environnements de développement :

- Un environnement Scala local avec un environnement local AWS Glue bibliothèque ETL Maven, telle que décrite dans la section [Développement local avec Scala](#) dans le guide du AWS Glue développeur.
- IntelliJ IDE, en téléchargeant l'IDE depuis. <https://www.jetbrains.com/idea/>

Rubriques

- [Développement de connecteurs Spark](#)
- [Développement de connecteurs Athena](#)
- [Développement de connecteurs JDBC](#)

- [Exemples d'utilisation de connecteurs personnalisés avec AWS Glue Studio](#)
- [En développement AWS Glue connecteurs pour AWS Marketplace](#)

Développement de connecteurs Spark

Vous pouvez créer un connecteur Spark avec DataSource l'API Spark V2 (Spark 2.4) pour lire les données.

Pour créer un connecteur Spark personnalisé

Suivez les étapes décrites dans le AWS Glue GitHub bibliothèque d'exemple pour le développement de connecteurs Spark, située à l'adresse <https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/Spark/README.md>.

Développement de connecteurs Athena

Vous pouvez créer un connecteur Athena à utiliser par AWS Glue and AWS Glue Studio pour interroger une source de données personnalisée.

Pour créer un connecteur Athena personnalisé

Suivez les étapes décrites dans le AWS Glue GitHub [bibliothèque d'exemples pour développer des connecteurs Athena](https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/Athena), située à l'adresse [https://github.com/aws-samples/ aws-glue-samples l'adresse/. tree/master/GlueCustomConnectors/development/Athena](https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/Athena)

Développement de connecteurs JDBC

Vous pouvez créer un connecteur qui utilise JDBC pour accéder à vos magasins de données.

Pour créer un connecteur JDBC personnalisé

1. Installer la AWS Glue Des bibliothèques d'exécution Spark dans votre environnement de développement local. Reportez-vous aux instructions du AWS Glue GitHub bibliothèque d'exemples à l' [adresse tree/master/GlueCustomConnectors/development/GlueSparkRuntime/README /.md](https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/GlueSparkRuntime/README.md).
2. Implémentez le pilote JDBC chargé de récupérer les données de la source de données. Reportez-vous à la [documentation Java](#) pour Java SE 8.

Créez un point d'entrée dans votre code qui AWS Glue Studio permet de localiser votre connecteur. Le champ Class name (Nom de classe) doit être le chemin complet de votre pilote JDBC.

3. Utilisation de l'API `GlueContext` pour lire les données avec le connecteur. Les utilisateurs peuvent ajouter d'autres options de saisie dans le AWS Glue Studio console pour configurer la connexion à la source de données, si nécessaire. Pour un exemple de code qui montre comment lire et écrire dans une base de données JDBC avec un connecteur JDBC personnalisé, voir Valeurs personnalisées [et](#) `ConnectionType`. AWS Marketplace

Exemples d'utilisation de connecteurs personnalisés avec AWS Glue Studio

Vous pouvez consulter les blogs suivants pour des exemples d'utilisation de connecteurs personnalisés :

- [Développement, test et déploiement de connecteurs personnalisés pour vos magasins de données avec AWS Glue](#)
- Apache Hudi : [écriture dans des tables Apache Hudi à l'aide de AWS Glue Connecteur personnalisé](#)
- Google BigQuery : [migration de données de Google vers Amazon S3 BigQuery à l'aide de AWS Glue connecteurs personnalisés](#)
- Snowflake (JDBC) : [réalisation de transformations de données à l'aide de Snowflake et AWS Glue](#)
- SingleStore: [Création d'un ETL rapide à l'aide SingleStore de et AWS Glue](#)
- Salesforce : [ingérez des données Salesforce dans Amazon S3 à l'aide du connecteur personnalisé CData JDBC avec - AWS Glue](#)
- MongoDB : Construction [AWS Glue Créez des tâches ETL à l'aide d'Amazon DocumentDB \(compatible avec MongoDB\) et MongoDB](#)
- Amazon Relational Database Service (Amazon RDS) : Bâtiment [AWS Glue Créez des tâches ETL en apportant vos propres pilotes JDBC pour Amazon RDS](#)
- MySQL (JDBC) : <https://github.com/aws-samples/aws-glue-samples//.scala/blob/master/GlueCustomConnectors/development/Spark/SparkConnectorMySQL>

En développement AWS Glue connecteurs pour AWS Marketplace

En tant que AWS partenaire, vous pouvez créer des connecteurs personnalisés et les télécharger AWS Marketplace pour les vendre à AWS Glue clients.

Le processus de développement du code du connecteur est le même que pour les connecteurs personnalisés, mais le processus de téléchargement et de vérification du code du connecteur est plus détaillé. Reportez-vous aux instructions de la section [Création de connecteurs pour AWS Marketplace](#) sur le GitHub site Web.

Restrictions relatives à l'utilisation de connecteurs et de connexions dans AWS Glue Studio

Lorsque vous utilisez des connecteurs personnalisés ou des connecteurs provenant de AWS Marketplace, prenez note des restrictions suivantes :

- L'API testConnection n'est pas prise en charge avec les connexions créées pour les connecteurs personnalisés.
- Le chiffrement du mot de passe de connexion Data Catalog n'est pas pris en charge avec les connecteurs personnalisés.
- Vous ne pouvez pas utiliser de marque-pages de tâche si vous spécifiez un prédicat de filtre pour un nœud de source de données qui utilise un connecteur JDBC.
- La création d'une connexion Marketplace n'est pas prise en charge en dehors de l'interface AWS Glue Studio utilisateur.

Tester un AWS Glue connexion

À titre de bonne pratique, avant d'utiliser un AWS Glue connexion dans une tâche ETL, utilisez AWS Glue console pour tester la connexion. AWS Glue utilise les paramètres de votre connexion pour confirmer qu'il peut accéder à votre banque de données et signale toute erreur. Pour plus d'informations sur AWS Glue connexions, voir [Connexion aux données](#).

Pour tester un AWS Glue connexion

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.

2. Dans le volet de navigation, sous Catalogue de données, choisissez Connexions. Vous pouvez également sélectionner Connexions aux données au-dessus de Catalogue de données dans le volet de navigation.
3. Dans Connexions, cochez la case en regard de la connexion souhaitée, puis choisissez Actions. Dans le menu déroulant, choisissez Tester la connexion.
4. Dans la boîte de dialogue Tester la connexion, sélectionnez un rôle ou choisissez Create IAM role pour accéder à la console AWS Identity and Access Management (IAM) afin de créer un nouveau rôle. Le rôle doit disposer d'autorisations dans le magasin de données.
5. Choisissez Confirmer.

Le test commence et peut prendre plusieurs minutes. Si le test échoue, choisissez Dépanner pour voir les étapes à suivre pour résoudre le problème.

6. Choisissez Logs pour afficher les connexions CloudWatch. Vous devez disposer des autorisations IAM requises pour afficher les journaux. Pour plus d'informations, consultez la section [Politiques AWS gérées \(prédéfinies\) pour les CloudWatch journaux](#) dans le guide de l'utilisateur Amazon CloudWatch Logs.

Configuration des AWS appels pour qu'ils passent par votre VPC

Le paramètre spécial de tâche vous `disable-proxy-v2` permet d'acheminer vos appels vers des services tels qu'Amazon S3 et AWS Glue via votre VPC. CloudWatch Par défaut, AWS Glue utilise un proxy local pour envoyer du trafic via le AWS Glue VPC afin de télécharger des scripts et des bibliothèques depuis Amazon S3, d'envoyer des demandes de publication de journaux et de métriques, et d'envoyer des demandes d'accès à AWS Glue des catalogues de données. CloudWatch Ce proxy permet à la tâche de fonctionner normalement même si votre VPC ne configure pas une route appropriée vers d'autres AWS services, tels qu'Amazon S3 CloudWatch, et. AWS Glue AWS Glue propose désormais un paramètre vous permettant de désactiver ce comportement. Pour plus d'informations, consultez la section [Paramètres du Job utilisés par AWS Glue](#). AWS Glue continuera à utiliser un proxy local pour publier CloudWatch les journaux de vos AWS Glue tâches.

Note

- Cette fonctionnalité est prise en charge pour les AWS Glue tâches avec AWS Glue la version 2.0 et supérieure. Lorsque vous utilisez cette fonction, vous devez vous assurer

que votre VPC a configuré un acheminement vers Amazon S3 via un point de terminaison d'un VPC de service ou via un NAT.

- Le paramètre de tâche obsolète `disable-proxy` achemine uniquement vos appels vers Amazon S3 pour le téléchargement de scripts et de bibliothèques via votre VPC. Il est recommandé d'utiliser le nouveau paramètre `disable-proxy-v2` à la place.

Exemple d'utilisation

Créez un AWS Glue emploi avec `disable-proxy-v2` :

```
aws glue create-job \  
  --name no-proxy-job \  
  --role GlueDefaultRole \  
  --command "Name=glueetl,ScriptLocation=s3://my-bucket/glue-script.py" \  
  --connections Connections="traffic-monitored-connection" \  
  --default-arguments '{"--disable-proxy-v2" : "true"}'
```

Connexion à un magasin de données JDBC dans un VPC

Généralement, vous créez des ressources dans Amazon Virtual Private Cloud (Amazon VPC) afin qu'elles ne soient pas accessibles via l'Internet public. Par défaut, AWS Glue impossible d'accéder aux ressources d'un VPC. Pour permettre l'accès AWS Glue aux ressources de votre VPC, vous devez fournir des informations de configuration supplémentaires spécifiques au VPC, notamment le sous-réseau et le groupe de sécurité du VPC. IDs AWS Glue utilise ces informations pour configurer des [interfaces réseau élastiques](#) qui permettent à votre fonction de se connecter en toute sécurité à d'autres ressources de votre VPC privé.

Lorsque vous utilisez un point de terminaison d'un VPC, ajoutez-le à votre table de routage. Pour de plus amples informations, consultez [Creating an interface VPC endpoint for AWS Glue](#) et [Prérequis](#).

Lorsque vous utilisez le chiffrement dans le catalogue de données, créez le point de terminaison de l'interface KMS et ajoutez-le à votre table de routage. Pour de plus amples informations, consultez [Creating a VPC endpoint for AWS KMS](#).

Accès à des données de VPC par l'intermédiaire d'interfaces réseau Elastic

Lorsque vous AWS Glue vous connectez à un magasin de données JDBC dans un VPC, il AWS Glue crée une interface réseau élastique (avec le préfixe `Glue_`) dans votre compte pour accéder à

vos données VPC. Vous ne pouvez pas supprimer cette interface réseau tant qu'elle est connectée à AWS Glue. Dans le cadre de la création de l'interface elastic network, AWS Glue associez un ou plusieurs groupes de sécurité à celle-ci. Pour AWS Glue permettre de créer l'interface réseau, les groupes de sécurité associés à la ressource doivent autoriser l'accès entrant avec une règle source. Cette règle contient un groupe de sécurité associé à la ressource. Cela permet à l'interface réseau Elastic d'accéder à votre magasin de données avec le même groupe de sécurité.

AWS Glue Pour autoriser la communication avec ses composants, spécifiez un groupe de sécurité doté d'une règle d'autoréférencement entrant pour tous les ports TCP. En créant une règle avec référence circulaire, vous pouvez restreindre la source au même groupe de sécurité dans le VPC et ne pas l'ouvrir à tous les réseaux. Le groupe de sécurité par défaut pour votre VPC peut déjà avoir une règle entrante avec référence circulaire pour ALL Traffic.

Vous pouvez créer des règles dans la console Amazon VPC. Pour mettre à jour les paramètres de règle via l' AWS Management Console, accédez à la console VPC (<https://console.aws.amazon.com/vpc/>) et sélectionnez le groupe de sécurité approprié. Spécifiez la règle entrante pour ALL TCP afin de disposer du même nom de groupe de sécurité en tant que source. Pour plus d'informations sur les règles des groupes de sécurité, consultez [Groupes de sécurité pour votre VPC](#).

À chaque interface réseau Elastic est affectée une adresse IP privée comprise dans la plage d'adresses IP des sous-réseaux spécifiés. Aucune adresse IP publique n'est attribuée à l'interface réseau. AWS Glue nécessite un accès à Internet (par exemple, pour accéder à AWS des services qui ne disposent pas de points de terminaison VPC). Vous pouvez configurer une instance NAT (Network Address Translation, traduction d'adresses réseau) dans votre VPC, ou utiliser la passerelle NAT Amazon VPC. Pour plus d'informations, veuillez consulter [NAT Gateways \(Passerelles NAT\)](#) dans le Guide de l'utilisateur Amazon VPC. Vous ne pouvez pas utiliser directement une passerelle Internet attachée à votre VPC en tant que routage dans votre table de routage de sous-réseau, car cela nécessite que l'interface réseau ait des adresses IP publiques.

Les attributs de réseau VPC `enableDnsHostnames` et `enableDnsSupport` doivent être définis sur `true`. Pour plus d'informations, consultez [Utilisation de DNS avec votre VPC](#).

Important

Ne placez pas votre magasin de données dans un sous-réseau public ou dans un sous-réseau privé qui ne dispose pas d'un accès Internet. En revanche, attachez-le uniquement à des sous-réseaux privés disposant d'un accès Internet via une instance NAT ou une passerelle NAT Amazon VPC.

Propriétés d'interface réseau Elastic

Pour créer l'interface réseau Elastic, vous devez indiquer les propriétés suivantes :

VPC

Nom du VPC qui contient votre magasin de données.

Sous-réseau

Sous-réseau du VPC qui contient votre magasin de données.

Groupes de sécurité

Les groupes de sécurité qui sont associés à votre magasin de données. AWS Glue associe ces groupes de sécurité à l'interface réseau Elastic qui est attachée à votre sous-réseau VPC. Pour autoriser des composants AWS Glue à communiquer, ainsi que pour empêcher l'accès depuis d'autres réseaux, au moins un groupe de sécurité choisi doit spécifier une règle entrante avec référence circulaire pour tous les ports TCP.

Pour en savoir plus sur la gestion d'un VPC avec Amazon Redshift, veuillez consulter [Gestion des clusters dans un Amazon Virtual Private Cloud \(VPC\)](#).

Pour plus d'informations sur la gestion d'un VPC avec Amazon Relational Database Service (Amazon RDS), veuillez consulter [Utilisation d'une instance de base de données Amazon RDS dans un VPC](#).

Utilisation d'une connexion MongoDB ou MongoDB Atlas

Après avoir créé une connexion pour MongoDB ou MongoDB Atlas, vous pouvez utiliser la connexion dans votre tâche ETL. Vous créez une table dans le AWS Glue Data Catalog et spécifiez la connexion MongoDB ou MongoDB Atlas pour l'attribut `connection` de la table.

AWS Glue stocke votre connexion `url` et vos informations d'identification dans la connexion MongoDB. Les formats d'URI de connexion sont les suivants :

- Pour MongoDB : `mongodb://host:port/database`. L'hôte peut être un nom d'hôte, une adresse IP ou un socket de domaine UNIX. Si la chaîne de connexion ne spécifie aucun port, elle utilise le port MongoDB par défaut, 27017.
- Pour MongoDB Atlas : `mongodb+srv://server.example.com/database`. L'hôte peut être un nom d'hôte qui suit et correspond à un enregistrement DNS SRV. Le format SRV ne nécessite pas de port et utilisera le port MongoDB par défaut, 27017.

En outre, vous pouvez spécifier les options dans votre script de tâche. Pour de plus amples informations, veuillez consulter [the section called “Connexion MongoDB”](#).

Analyse d'un magasin de données Amazon S3 à l'aide d'un point de terminaison d'un VPC

Pour des raisons de sécurité, d'audit ou de contrôle, vous pouvez souhaiter que votre magasin de données Amazon S3 ou vos tables du catalogue de données basées sur Amazon S3 soient uniquement accessibles via un environnement Amazon Virtual Private Cloud (Amazon VPC). Cette rubrique décrit la manière de créer et de tester une connexion au magasin de données Amazon S3 ou des tables du catalogue de données basées sur Amazon S3 dans un point de terminaison d'un VPC à l'aide du type de connexion Network.

Effectuez les tâches suivantes pour exécuter un crawler sur le magasin de données :

- [the section called “Prérequis”](#)
- [the section called “Création de la connexion à Amazon S3”](#)
- [the section called “Test de la connexion à Amazon S3”](#)
- [the section called “Création d'un crawler pour un magasin de données Amazon S3”](#)
- [the section called “Exécution d'un crawler”](#)

Prérequis

Vérifier que vous avez satisfait à ces conditions préalables pour la configuration de votre magasin de données Amazon S3 ou vos tables du catalogue de données basées sur Amazon S3 pour y accéder via un environnement Amazon Virtual Private Cloud (Amazon VPC).

- Un VPC configuré. Par exemple : vpc-01685961063b0d84b. Pour plus d'informations, consultez [Mise en route avec Amazon VPC](#) dans le Guide de l'utilisateur Amazon VPC.
- Un point de terminaison Amazon S3 attaché au VPC. Par exemple : vpc-01685961063b0d84b. Pour de plus amples informations, veuillez consulter [Points de terminaison pour Amazon S3](#) dans le Guide de l'utilisateur Amazon VPC.

Name	VPC ID	State	IPv4 CIDR	IPv6	DHCP options set	Main Route table	Main Network ACL	Tenancy	Default VPC
privateVPC	vpc-01685961063b0d84b	available	192.168.1.0/24	-	dopt-a79e5acc	rtb-0750198567d5...	acl-02d197f2c9fbe46...	default	No

VPC: vpc-01685961063b0d84b

Description

CIDR Blocks

Flow Logs

Tags

VPC ID	vpc-01685961063b0d84b	Tenancy	default
State	available	Default VPC	No
IPv4 CIDR	192.168.1.0/24	IPv6 CIDR	-
IPv6 Pool	-	DNS resolution	Enabled
Network ACL	acl-02d197f2c9fbe46be	DNS hostnames	Disabled
DHCP options set	dopt-a79e5acc	Route table	rtb-0750198567d5b5202
Owner	261353713322		

- Entrée d'acheminement pointant vers le point de terminaison d'un VPC. Par exemple vpce-0ec5da4d265227786 dans la table de routage utilisée par le point de terminaison d'un VPC (vpce-0ec5da4d265227786).

Route Table ID : rtb-0750198567d5b5202

Add filter

	Name	Route Table ID	Explicit subnet association	Edge associations	Main	VPC ID
		rtb-0750198567d5b5202	-	-	Yes	vpc-01685961063b0d84b ...

Route Table: rtb-0750198567d5b5202

Summary

Routes

Subnet Associations

Edge Associations

Route Propagation

Tags

Edit routes

View All routes

Destination	Target	Status	Propagate
192.168.1.0/24	local	active	No
pl-7ba54012 (com.amazonaws.us-east-2.s3, 52.219.80.0/20, 3.5.128.0/22, 3.5.132.0/23, 52.219.96.0/20, 52.92.76.0/22)	vpce-0ec5da4d265227786	active	No

- Une ACL réseau attachée au VPC autorise le trafic.
- Un groupe de sécurité attaché au VPC autorise le trafic.

Création de la connexion à Amazon S3


Généralement, vous créez des ressources dans Amazon Virtual Private Cloud (Amazon VPC) afin qu'elles ne soient pas accessibles via l'Internet public. Par défaut, AWS Glue impossible d'accéder aux ressources d'un VPC. Pour permettre l'accès AWS Glue aux ressources de votre VPC, vous

devez fournir des informations de configuration supplémentaires spécifiques au VPC, notamment le sous-réseau et le groupe de sécurité du VPC. IDs IDs Pour créer une connexion Network, vous devez spécifier les informations suivantes :

- ID d'un VPC
- Un sous-réseau au sein du VPC
- Un groupe de sécurité

Pour configurer une connexion Network :

1. Choisissez Add connection (Ajouter une connexion) dans le panneau de navigation de la console AWS Glue .
2. Saisissez le nom de la connexion, puis choisissez Network (Réseau) comme type de connexion. Choisissez Suivant.



Add connection ✕

- ☒ Connection properties
- ☐ Connection access
- ☐ Review all steps

Set up your connection's properties.

For more information, see [Working with Connections](#).

Connection name

TestNetworkConnection

Connection type

Network ▼

Description (optional)

This is a demo Network Connection

Next

3. Configurez les informations du VPC, du sous-réseau et des groupes de sécurité.
- VPC : choisissez le nom du VPC qui contient votre magasin de données.
 - Subnet (Sous-réseau) : choisissez le sous-réseau au sein de votre VPC.
 - Security groups (Groupes de sécurité) : choisissez un ou plusieurs groupes de sécurité qui autorisent l'accès au stockage des données dans votre VPC.

Add connection

✔ Connection properties

TestNetworkConnecti
on
Type: Network

○ Connection access

○ Review all steps

Set up access to your data store.

For more information, see [Working with Connections](#).

VPC

Choose the VPC name that contains your data store.

vpc-01685961063b0d84b | privateVPC

Subnet

Choose the subnet within your VPC.

subnet-0b350d86953aa6d60 | Range192

Security groups

Choose one or more security groups that allow access to the data store in your VPC. AWS Glue associates these security groups to the ENI attached to your subnet. To allow AWS Glue components to communicate and also prevent access from other networks, at least one chosen security group must specify a self-referencing inbound rule for all TCP ports.

✔ Group ID	Group name
✔ sg-0ce8b36fb6206c56e	default

Back

Next

4. Choisissez Suivant.

5. Vérifiez les informations de connexion et choisissez Finish (Terminer).

Création de la connexion à Amazon S3

1206

Add connection

☒ **Connection properties**

TestNetworkConnection
Type: Network

☒ **Connection access**

VPC Id:
vpc-01685961063b0d84b

☐ **Review all steps**

Connection properties

Name	TestNetworkConnection
Type	Network
Description (optional)	This is a demo Network Connection

Connection access

VPC Id	vpc-01685961063b0d84b
Subnet	subnet-0b350d86953aa6d60
Security groups	sg-0ce8b36fb6206c56e

Back

Finish

Test de la connexion à Amazon S3

Une fois que vous avez créé votre connexion Network, vous pouvez tester la connectivité à votre magasin de données Amazon S3 dans un point de terminaison d'un VPC.

Les erreurs suivantes peuvent se produire lors du test d'une connexion :


- **INTERNET CONNECTION ERROR** (Erreur de connexion Internet) : indique un problème de connexion Internet
- **INVALID BUCKET ERROR** (Erreur de compartiment non valide) : indique un problème avec le compartiment Amazon S3
- **S3 CONNECTION ERROR** (Erreur de connexion S3) : indique un échec de connexion à Amazon S3
- **INVALID CONNECTION TYPE** (Type de connexion non valide) : indique que le type de connexion n'a pas la valeur attendue, NETWORK
- **INVALID CONNECTION TEST TYPE** (Type de test de connexion non valide) : indique un problème avec le type de test de connexion réseau
- **INVALID TARGET** (Cible non valide) : indique que le compartiment Amazon S3 n'a pas été spécifié correctement

Test de la connexion à Amazon S3

1207

Pour tester une connexion Network :

1. Sélectionnez la connexion Network (Réseau) dans la console AWS Glue .
2. Choisissez Test connection (Tester la connexion).
3. Choisissez le rôle IAM que vous avez créé à l'étape précédente et spécifiez un compartiment Amazon S3.
4. Choisissez Test connection (Tester la connexion) pour démarrer le test. Cela peut prendre quelques instants pour afficher le résultat.



Si vous recevez une erreur, effectuez les vérifications suivantes :

- Les privilèges corrects sont fournis au rôle sélectionné.
- Le compartiment Amazon S3 approprié est fourni.
- Les groupes de sécurité et la liste ACL réseau autorisent le trafic entrant et sortant requis.

- Le VPC que vous avez spécifié est connecté à un point de terminaison d'un VPC Amazon S3.

Après avoir testé la connexion, vous pouvez créer un crawler.

Création d'un crawler pour un magasin de données Amazon S3

Vous pouvez désormais créer un crawler qui spécifie la connexion Network que vous avez créée. Pour plus d'informations sur la création d'un crawler, veuillez consulter [Configuration d'un crawler](#).

1. Commencez par choisir Crawlers dans le volet de navigation de la AWS Glue console.
2. Choisissez Add crawler (Ajouter un crawler).
3. Indiquez le nom du crawler, puis choisissez Next (Suivant).
4. Lorsque vous êtes invité à indiquer la source de données, sélectionnez S3, puis spécifiez le préfixe du compartiment Amazon S3 et la connexion que vous avez créée plus tôt.

The screenshot shows the 'Add crawler' wizard in the AWS Glue console. The left sidebar contains a navigation menu with the following items: 'Crawler info' (checked), 'TestNetworkConnection', 'Crawler source type' (checked), 'Data stores', 'Data store' (selected), 'S3:', 'IAM Role', 'Schedule', 'Output', and 'Review all steps'. The main panel is titled 'Add a data store' and contains the following sections:

- Choose a data store:** A dropdown menu with 'S3' selected.
- Connection:** A dropdown menu with 'AddNetworkConnection' selected. Below it, a note states: 'Optionally include a Network connection to use with this S3 target. Note that each crawler is limited to one Network connection so any future S3 targets will also use the same connection (or none, if left blank).' There is an 'Add connection' button.
- Crawl data in:** A radio button labeled 'Specified path' is selected.
- Include path:** A text input field contains 's3://crawlttestfiles'. Below it, a note states: 'All folders and files contained in the include path are crawled. For example, type s3://MyBucket/MyFolder/ to crawl all objects in MyFolder within MyBucket.' There is an 'Exclude patterns (optional)' link.

At the bottom right of the main panel are 'Back' and 'Next' buttons. On the far right, a 'Chosen data stores' panel shows 'S3:' with a close button.

5. Si nécessaire, ajoutez un autre magasin de données sur la même connexion réseau.
6. Choisissez le rôle IAM. Le rôle IAM doit autoriser l'accès au service AWS Glue et au compartiment Amazon S3. Pour de plus amples informations, veuillez consulter [the section called "Configuration d'un crawler"](#).

Add crawler

✓ Crawler info

TestNetworkConnecti
on

✓ Crawler source type

Data stores

✓ Data store

S3: s3://crawlertestf...

○ IAM Role

○ Schedule

○ Output

○ Review all steps

Choose an IAM role

The IAM role allows the crawler to run and access your Amazon S3 data stores. [Learn more](#)

- ☐ Update a policy in an IAM role
- ☒ Choose an existing IAM role
- ☐ Create an IAM role

IAM role ⓘ

AWSGlueServiceRole-glue



This role must provide permissions similar to the AWS managed policy, **AWSGlueServiceRole**, plus access to your data stores.

- s3://crawlertestfiles

You can also create an IAM role on the [IAM console](#).

Back

Next

7. Définissez le planificateur pour le crawler.

8. Choisissez une base de données existante dans le catalogue de données ou créez-en une.

Add crawler



✓ Crawler info

TestNetworkConnecti
on

✓ Crawler source type

Data stores

✓ Data store

S3: s3://crawlertestf...

✓ IAM Role

arn:aws:iam::2613537
13322:role/service-
role/AWSGlueService
Role-glue

✓ Schedule

Run on demand

○ Output

○ Review all steps

Configure the crawler's output

Database ⓘ

testnetworkconnectiondb

Add database

Prefix added to tables (optional) ⓘ

Type a prefix added to table names

▸ Grouping behavior for S3 data (optional)

▸ Configuration options (optional)

Back

Next

9. Terminez la configuration restante.

Création d'un crawler pour les tables du catalogue de données basées sur Amazon S3

Vous pouvez désormais créer un crawler qui spécifie la connexion Network que vous avez créée et un type de source du catalogue. Pour plus d'informations sur la création d'un crawler, veuillez consulter [Configuration d'un crawler](#).

1. Commencez par choisir Crawlers dans le volet de navigation de la AWS Glue console.
2. Choisissez Add crawler (Ajouter un crawler).
3. Indiquez le nom du crawler, puis choisissez Next (Suivant).
4. Lorsque vous êtes invité à indiquer le type de source du crawler, sélectionnez Existing catalog tables (Tables catalogue existantes), et indiquez les tables de catalogue existantes à analyser dans la liste des tables disponibles.

Add crawler

Choose catalog tables

Showing: 0 - 0

Name	Database	Location	Classification
No items selected			

Showing: 1 - 3

Name	Database	Location	Classification
Add s3_event_crawl_demo	test-sampling-db	s3://s3-event-crawl-demo/	json
Add test_int5100_idf_20210310094002_0800_obfusca...	test-large-xml	s3://crawltickets/TEST_INT5100_IDF_20210310...	Unknown
Add test_int5100_idf_20210310094002_0800_obfusca...	test-cx-whitelist	s3://crawltickets/TEST_INT5100_IDF_20210310...	xml

Connection

Select a connection

[Add connection](#)

5. Choisissez le rôle IAM. Le rôle IAM doit autoriser l'accès au service AWS Glue et au compartiment Amazon S3. Pour de plus amples informations, veuillez consulter [the section called "Configuration d'un crawler"](#).
6. Définissez le planificateur pour le crawler.
7. Choisissez une base de données existante dans le catalogue de données ou créez-en une.
8. Terminez la configuration restante et passez en revue vos étapes.

Add crawler

Crawler info

test

Crawler source type

Existing catalog tables

Catalog tables

test_int5100_idf_20...

IAM Role

arn:aws:iam::804918391416:role/service-role/AWSGlueServiceRole-crawler-test

Schedule

Run on demand

Output

Review all steps

Use Lake Formation Data Catalog

false

Catalog tables

Database

test-large-xml

Table name

test_int5100_idf_20210310094002_0800_obfuscated_xml

Connection

test

IAM role

IAM role

arn:aws:iam::804918391416:role/service-role/AWSGlueServiceRole-crawler-test

Schedule

Schedule

Run on demand

Output

Database

Prefix added to tables (optional)

Create a single schema for each S3 path

Table level (optional)

Data Lineage (optional)

Configuration options

DISABLE

true

Back

Finish

Exécution d'un crawler

Exécutez votre crawler.

AWS Glue

Data catalog

Databases

Tables

Connections

Crawlers

A crawler connects to a data store, progresses through a prioritized list of classifiers to determine the schema for your data, and then creates metadata tables in your data catalog.

Crawler **TestNetworkConnection** was created to run on demand. [Run it now?](#)

User preferences

Résolution des problèmes

Pour résoudre les problèmes liés aux compartiments Amazon S3 à l'aide d'une passerelle VPC, veuillez consulter [Pourquoi ne puis-je pas me connecter à un compartiment S3 à l'aide d'un point de terminaison d'un VPC passerelle ?](#)

Travailler avec des AWS Lake Formation données protégées

Accès complet à la table

AWS Glue prend en charge l'accès complet aux tables (FTA) pour les tables AWS Lake Formation protégées. Cela permet à vos tâches ETL de lire et d'écrire des données avec des autorisations complètes sur les tables.

Prérequis

- Rôles et autorisations IAM appropriés
- AWS Lake Formation configuré pour votre catalogue de données
- Types de tables compatibles (Hive ou Iceberg)

Considérations clés

Autorisations requises

- `lakeformation:GetDataAccess` autorisation IAM
- AWS Lake Formation autorisations de table
- Autorisations d'accès au compartiment Amazon S3

Types de tables pris en charge

- Tables Hive
- Tables Iceberg

Limites

- Non compatible avec Spark Streaming
- Ne peut pas être utilisé simultanément avec un contrôle d'accès précis
- Ne prend pas en charge les tables Delta ou Hudi

Bonnes pratiques

1. Assurez-vous que les rôles IAM sont correctement configurés avant l'exécution de la tâche

2. Tester les autorisations d'accès dans un environnement de développement
3. Surveillez les journaux d'exécution des tâches pour détecter les problèmes liés aux autorisations
4. Conservez une documentation claire des modèles d'accès

Résolution des problèmes

Les problèmes courants incluent :

- Autorisations IAM manquantes
- AWS Lake Formation Configuration incorrecte
- Problèmes de compatibilité des types de tables

Pour obtenir des instructions de configuration complètes et des détails de configuration, voir [Utilisation AWS Lake Formation avec un accès complet aux tables](#).

Résolution des problèmes de connexion dans AWS Glue

Lorsqu'un AWS Glue robot ou une tâche utilise les propriétés de connexion pour accéder à un magasin de données, vous pouvez rencontrer des erreurs lorsque vous essayez de vous connecter. AWS Glue utilise des adresses IP privées dans le sous-réseau lorsqu'il crée des interfaces réseau élastiques dans le cloud privé virtuel (VPC) et le sous-réseau que vous avez spécifiés. Les groupes de sécurité spécifiés dans la connexion sont appliqués sur chacune des interfaces réseau Elastic. Vérifiez si les groupes de sécurité permettent l'accès sortant et autorisent la connectivité au cluster de base de données.

En outre, Apache Spark nécessite une connexion bidirectionnelle entre nœuds de pilote et nœuds d'exécuteur. L'un des groupes de sécurité doit autoriser les règles entrantes sur tous les ports TCP. Vous pouvez l'empêcher d'être ouvert sur le monde en limitant la source du groupe de sécurité à elle-même avec un groupe de sécurité à auto-référencement.

Voici quelques actions typiques que vous pouvez adopter pour résoudre les problèmes de connexion :

- Vérifiez l'adresse du port de votre connexion.
- Vérifiez la chaîne de nom d'utilisateur et de mot de passe de votre connexion ou votre secret.
- Pour un magasin de données JDBC, vérifiez qu'il autorise les connexions entrantes.

- Vérifiez que votre magasin de données peut être accessible au sein de votre VPC.
- Si vous stockez vos informations de connexion à l'aide de AWS Secrets Manager, assurez-vous que votre rôle IAM pour AWS Glue est autorisé à accéder à votre secret. Pour plus d'informations, consultez la rubrique [Exemple : Autorisation pour récupérer des valeurs de secrets](#) dans le Guide de l'utilisateur AWS Secrets Manager . En fonction de votre configuration réseau, vous devrez peut-être également créer un point de terminaison d'un VPC pour établir une connexion privée entre votre VPC et gestionnaire de secrets Pour plus d'informations, consultez la section [Utilisation d'un point de AWS Secrets Manager terminaison VPC](#).

Tutoriel : Utilisation du AWS Glue connecteur pour Elasticsearch

Elasticsearch est un célèbre moteur open source de recherche et d'analyse qui peut être utilisé, entre autres, pour l'analyse de journaux, la surveillance en temps réel des applications et l'analyse des flux de clics. Vous pouvez l'utiliser OpenSearch comme magasin de données pour vos tâches d'extraction, de transformation et de chargement (ETL) en configurant le AWS Glue connecteur pour Elasticsearch dans AWS Glue Studio Ce connecteur est disponible gratuitement sur [AWS Marketplace](#).

Note

Le [connecteur Elasticsearch Spark AWS Marketplace](#) est devenu obsolète. Veuillez utiliser le [connecteur AWS Glue pour Elasticsearch](#) à la place.

Dans ce didacticiel, nous allons vous montrer comment vous connecter à vos nœuds Amazon OpenSearch Service en un minimum d'étapes.

Rubriques

- [Prérequis](#)
- [Étape 1 : \(Facultatif\) Créez un AWS secret pour les informations de votre OpenSearch cluster](#)
- [Étape 2 : S'abonner au connecteur](#)
- [Étape 3 : activer le connecteur AWS Glue Studio et créer une connexion](#)
- [Étape 4 : Configurer un rôle IAM pour votre tâche ETL](#)
- [Étape 5 : créer une tâche qui utilise la OpenSearch connexion](#)
- [Étape 6 : Exécuter la tâche](#)

Prérequis

Pour utiliser ce didacticiel, vous devez disposer des éléments suivants :

- Accès à AWS Glue Studio
- Accès à un OpenSearch cluster dans le AWS cloud
- (Facultatif) Accès à AWS Secrets Manager.

Étape 1 : (Facultatif) Créez un AWS secret pour les informations de votre OpenSearch cluster

Pour stocker et utiliser en toute sécurité vos informations d'identification de connexion, enregistrez vos informations d'identification au format AWS Secrets Manager. Le secret que vous créez sera utilisé plus tard dans le didacticiel par la connexion. Les paires clé-valeur d'identification seront introduites dans le AWS Glue Connector for Elasticsearch en tant qu'options de connexion normales.

Pour plus d'informations sur la création de secrets, veuillez consulter la rubrique [Création et gestion des secrets avec AWS Secrets Manager](#) dans le Guide de l'utilisateur AWS Secrets Manager .

Pour créer un AWS secret

1. Connectez-vous à la [console AWS Secrets Manager](#).
2. Sur la page de présentation du service ou la page de la liste Secrets, sélectionnez Store a new secret (Stocker un nouveau secret).
3. Sur la page Store a new secret (Stocker un nouveau secret), sélectionnez Other type of secret (Autre type de secret). Cette option signifie que vous devez fournir la structure et les détails de votre secret.
4. Ajoutez une paire clé/valeur pour le nom d'utilisateur du OpenSearch cluster. Par exemple :
`es.net.http.auth.user: username`
5. Sélectionnez + Add row (+ Ajouter une ligne), puis saisissez une autre paire clé-valeur pour le mot de passe. Par exemple :
`es.net.http.auth.pass: password`
6. Choisissez Suivant.
7. Saisissez un nom de secret. Par exemple : my-es-secret. Vous pouvez ajouter une description si vous le souhaitez.

Enregistrez le nom secret, qui sera utilisé plus tard dans ce didacticiel, puis sélectionnez Next (Suivant).

8. Sélectionnez à nouveau Next (Suivant), puis Store (Stocker) pour créer le secret.

Étape suivante

Étape 2 : S'abonner au connecteur

Étape 2 : S'abonner au connecteur

Le AWS Glue connecteur pour Elasticsearch est disponible gratuitement à l'adresse.

[AWS Marketplace](#)

Pour vous abonner au AWS Glue Connector for Elasticsearch sur AWS Marketplace

1. Si vous n'avez pas encore configuré votre AWS compte pour utiliser le License Manager, procédez comme suit :
 - a. Ouvrez la AWS License Manager console à l'adresse <https://console.aws.amazon.com/license-manager>.
 - b. Sélectionnez Create customer managed license (Créer une licence gérée par le client).
 - c. Dans la fenêtre Autorisations IAM (configuration unique), choisissez J'accorde AWS License Manager les autorisations requises, puis choisissez Accorder les autorisations.

Si vous ne voyez pas cette fenêtre, cela signifie que vous avez déjà configuré les autorisations nécessaires.

2. Ouvrez le fichier AWS Glue Studio console à <https://console.aws.amazon.com/gluestudio/>.
3. Dans la AWS Glue Studio console, développez l'icône du menu ()
, puis choisissez Connectors dans le volet de navigation.
4. Sur la page Connectors (Connecteurs), sélectionnez Go to AWS Marketplace (Accéder à MKT).
5. Dans AWS Marketplace la section Rechercher des AWS Glue Studio produits, saisissez AWS Glue Connector for Elasticsearch dans le champ de recherche, puis appuyez sur Entrée.
6. Sélectionnez le nom du connecteur, Connecteur AWS Glue pour Elasticsearch.

7. Sur la page produit du connecteur, utilisez les onglets pour afficher des informations sur le connecteur. Lorsque vous êtes prêt à continuer, sélectionnez Continue to Subscribe (Continuer pour s'abonner).
8. Lisez les conditions d'utilisation du logiciel. Cliquez sur Accept Terms (Accepter les conditions d'utilisation).
9. Une fois le processus d'abonnement terminé, la notification suivante apparaît : « Merci de vous être abonné à ce produit ! Vous pouvez à présent configurer votre logiciel. » Au-dessus de la bannière se trouve le bouton Continue to Configuration (Continuer à configurer). Choisissez Continue to Configuration (Continuer vers Configuration).
10. Choisissez l'option remplissage sur la page Configure this software (Configurer ce logiciel). Vous pouvez choisir entre AWS Glue 1.0/2.0 ou AWS Glue 3.0. Puis sélectionnez Continue to Launch (Continuer pour lancer).

Étape suivante

[Étape 3 : activer le connecteur AWS Glue Studio et créer une connexion](#)

Étape 3 : activer le connecteur AWS Glue Studio et créer une connexion

Après avoir choisi Continuer au lancement, la page Lancer ce logiciel s'affiche dans AWS Marketplace. Après avoir utilisé le lien pour activer le connecteur AWS Glue Studio, vous créez une connexion.

Pour déployer le connecteur et créer une connexion dans AWS Glue Studio

1. Sur la page Lancer ce logiciel dans la AWS Marketplace console, choisissez Instructions d'utilisation, puis cliquez sur le lien dans la fenêtre qui apparaît.

Votre navigateur est redirigé vers la page de connexion de la AWS Glue Studio console Créer une place de marché.

2. Saisissez un nom pour la connexion. olpPar exemple : my-es-connection.
3. Dans la section Connection access (Accès à la connexion), pour Connection credential type (Type d'informations d'identification de connexion), sélectionnez User name and password (Nom d'utilisateur et mot de passe).
4. Pour Secret AWS , saisissez le nom de votre secret. olpPar exemple : my-es-secret.
5. Dans la section Options réseau, entrez les informations VPC pour vous connecter au OpenSearch cluster.

6. Sélectionnez **Create connection and activate connector** (Créer une connexion et activer le connecteur).

Étape suivante

[Étape 4 : Configurer un rôle IAM pour votre tâche ETL](#)

Étape 4 : Configurer un rôle IAM pour votre tâche ETL

Lorsque vous créez la tâche AWS Glue ETL, vous spécifiez un rôle AWS Identity and Access Management (IAM) pour la tâche à utiliser. Le rôle doit accorder l'accès à toutes les ressources utilisées par la tâche, y compris Amazon S3 (pour toutes les sources, cibles, scripts, fichiers de pilotes et répertoires temporaires), ainsi qu'aux AWS Glue Data Catalog objets.

Le rôle IAM assumé pour la tâche AWS Glue ETL doit également avoir accès au secret créé dans la section précédente. Par défaut, le rôle `AWSGlueServiceRole` géré par AWS n'a pas accès au secret. Pour configurer le contrôle d'accès pour vos secrets, consultez les rubriques [Authentification et contrôle d'accès pour AWS Secrets Manager](#) et [Limiting Access to Specific Secrets](#).

Pour configurer un rôle IAM pour votre tâche ETL

1. Configurez les autorisations décrites dans [the section called “Examinez les autorisations IAM nécessaires pour les tâches ETL”](#).
2. Configurez les autorisations supplémentaires nécessaires lors de l'utilisation de connecteurs avec AWS Glue Studio, comme décrit dans [the section called “Autorisations requises pour l'utilisation de connecteurs”](#).

Étape suivante

[Étape 5 : créer une tâche qui utilise la OpenSearch connexion](#)

Étape 5 : créer une tâche qui utilise la OpenSearch connexion

Après avoir créé un rôle pour votre tâche ETL, vous pouvez créer une tâche AWS Glue Studio qui utilise la connexion et le connecteur d'Open Spark ElasticSearch.

Si votre tâche est exécutée dans un Amazon Virtual Private Cloud (Amazon VPC), assurez-vous que le VPC est correctement configuré. Pour de plus amples informations, veuillez consulter [the section called “Configuration d'un VPC pour votre tâche ETL”](#).

Pour créer une tâche qui utilise le connecteur Elasticsearch Spark

1. Dans AWS Glue Studio, choisissez Connectors.
2. Dans Your connections (Vos connexions), sélectionnez la connexion que vous venez de créer et sélectionnez Create job (Créer une tâche).
3. Dans l'éditeur de travail visuel, sélectionnez le nœud Data source (Source de données). Sur la droite, dans l'onglet Data source properties — Connector (Propriétés de la source de données — Connecteur), configurez des informations supplémentaires pour le connecteur.
 - a. Sélectionnez Add schema (Ajouter un schéma) et saisissez le schéma de l'ensemble de données dans la source de données. Les connexions n'utilisent pas les tables stockées dans le catalogue de données, ce qui signifie que celui-ci AWS Glue Studio ne connaît pas le schéma des données. Vous devez fournir manuellement ces informations de schéma. Pour obtenir des instructions sur l'utilisation de l'éditeur de schéma, veuillez consulter [the section called “Modifier le schéma d'un nœud de transformation personnalisé”](#).
 - b. Développez Connection options (Options de connexion).
 - c. Choisissez Ajouter une nouvelle option et entrez les informations requises pour le connecteur qui n'ont pas été saisies dans le AWS secret :
 - es.nodes : `https ://< point de terminaison de OpenSearch domaine>`
 - es.port : 443
 - chemin : test
 - es.nodes.wan.only. : true

Pour en savoir plus sur ces options de connexion, reportez-vous à <https://www.elastic.co/guide/en/elasticsearch/hadoop/current/configuration.html>.

4. Ajoutez un nœud cible au graphique.

Votre cible de données peut être Amazon S3, ou elle peut utiliser les informations d'un AWS Glue Data Catalog ou d'un connecteur pour écrire des données dans un emplacement différent. Par exemple, vous pouvez utiliser une table Data Catalog pour écrire dans une base de données dans Amazon RDS, ou vous pouvez utiliser un connecteur comme cible de données pour écrire dans des magasins de données qui ne sont pas pris en charge de manière native dans AWS Glue.

Si vous sélectionnez un connecteur pour votre cible de données, vous devez choisir une connexion créée pour ce connecteur. En outre, si le fournisseur de connecteurs l'exige, vous devez ajouter des options pour fournir des informations supplémentaires au connecteur. Si vous utilisez une connexion contenant des informations relatives à un AWS secret, il n'est pas nécessaire de fournir le nom d'utilisateur et le mot de passe d'authentification dans les options de connexion.

5. Ajoutez éventuellement des sources de données supplémentaires et un ou plusieurs nœuds de transformation, comme décrit dans [the section called “Transformez les données avec AWS Glue transformations gérées”](#).
6. Configurez les propriétés du travail comme décrit dans [the section called “Modifier les propriétés de tâche”](#), en commençant par l'étape 3, et enregistrez la tâche.

Étape suivante

[Étape 6 : Exécuter la tâche](#)

Étape 6 : Exécuter la tâche

Après avoir enregistré votre tâche, vous pouvez exécuter la tâche pour effectuer les opérations ETL.

Pour exécuter le job que vous avez créé pour le AWS Glue Connector for Elasticsearch

1. À l'aide de la AWS Glue Studio console, sur la page de l'éditeur visuel, choisissez Exécuter.
2. Dans la bannière de succès, sélectionnez Run Details (Détails de l'exécution), ou l'onglet Runs (Exécutions) de l'éditeur visuel pour afficher des informations sur l'exécution de la tâche.

Création AWS Glue d'emplois grâce à des sessions interactives

Les ingénieurs de données peuvent créer AWS Glue des tâches plus rapides et plus faciles qu'auparavant grâce à des sessions interactives dans AWS Glue.

Rubriques

- [Vue d'ensemble de AWS Glue sessions interactives](#)
- [Démarrage avec AWS Glue sessions interactives](#)
- [Configuration AWS Glue sessions interactives pour Jupyter et AWS Glue Studio blocs-notes](#)
- [Conversion d'un script ou d'un bloc-notes en AWS Glue tâche](#)
- [Utilisation des opérations de streaming dans AWS Glue sessions interactives](#)
- [Développement et test de scripts AWS de tâches Glue localement](#)
- [Points de terminaison de développement](#)

Vue d'ensemble de AWS Glue sessions interactives

Avec AWS Glue sessions interactives, vous pouvez rapidement créer, tester et exécuter des applications de préparation et d'analyse des données. Les séances interactives fournissent une interface programmatique et visuelle pour la création et le test de scripts d'extraction, transformation et chargement (ETL) pour la préparation de données. Les sessions interactives exécutent les applications d'analyse Apache Spark et fournissent un accès à la demande à un environnement d'exécution Spark distant. AWS Glue gère de manière transparente Spark sans serveur pour ces sessions interactives.

Les sessions interactives sont flexibles, vous pouvez donc créer et tester des applications à partir de l'environnement de votre choix. Vous pouvez créer et utiliser des sessions interactives par le biais de l'API AWS Command Line Interface et de l'API. Vous pouvez utiliser des blocs-notes compatibles avec Jupyter pour créer et tester visuellement vos scripts de bloc-notes. Les sessions interactives fournissent un noyau Jupyter open source qui s'intègre presque partout où Jupyter le fait, y compris avec PyCharm IntelliJ et VS Code. IDEs Cela vous permet de coder dans votre environnement local et de l'exécuter de manière transparente sur le backend des séances interactives.

À l'aide de l'API des séances interactive, les clients peuvent exécuter par programmation des applications utilisant l'analyse Apache Spark sans avoir à gérer l'infrastructure Spark. Vous pouvez exécuter une ou plusieurs instructions Spark au cours d'une seule séance interactive.

Les séances interactives offrent donc un moyen plus rapide, moins coûteux et plus flexible de créer et d'exécuter des applications de préparation et d'analytique des données. Pour apprendre à utiliser les sessions interactives, consultez la documentation de cette section. [Magics soutenu par AWS Glue](#)

Limites

- Les signets de tâches ne sont pas pris en charge dans les séances interactives.
- La création de tâches de bloc-notes à l'aide du n' AWS Command Line Interface est pas prise en charge.
- AWS Glue Studio les ordinateurs portables ne supportent pas Scala.

Démarrage avec AWS Glue sessions interactives

Ces sections décrivent comment exécuter AWS Glue sessions interactives au niveau local.

Conditions préalables à la configuration locale des séances interactives

Les conditions suivantes sont requises pour installer des séances interactives :

- Les versions de Python prises en charge vont des versions 3.6 à 3.10 et ultérieures.
- Consultez les sections ci-dessous pour les instructions MacOS/Linux et Windows.

Installation de Jupyter et de sessions AWS Glue interactives (noyaux Jupyter)

Pour installer le noyau localement, procédez comme suit.

La commande `install-glue-kernels` installe les KernelSpec Jupyter pour les noyaux Pyspark et Spark et installe également les logos dans le bon répertoire.

```
pip3 install --upgrade jupyter boto3 aws-glue-sessions
```

```
install-glue-kernels
```

Exécution de Jupyter

Pour exécuter Jupyter Notebook, effectuez les étapes suivantes.

1. Pour lancer Jupyter Notebook, exécutez la commande suivante.

```
jupyter notebook
```

2. Choisissez Nouveau, puis choisissez l'une des AWS Glue noyaux à partir desquels commencer à coder AWS Glue.

Configuration des informations d'identification de séance et de région

Instructions MacOS/Linux

AWS Glue les sessions interactives nécessitent les mêmes autorisations IAM que AWS Glue Emplois et points de terminaison de développement. Spécifiez le rôle utilisé avec des séances interactives de l'une des deux manières suivantes :

1. Avec magics `%iam_role` et `%region`
2. Avec une ligne supplémentaire dans `~/.aws/config`

Configuration d'un rôle de séance avec magic

Dans la première cellule, saisissez `%iam_role <YourGlueServiceRole>` dans la première cellule exécutée.

Configuration d'un rôle de séance avec `~/.aws/config`

AWS Glue Le rôle de service pour les sessions interactives peut être spécifié dans le bloc-notes lui-même ou stocké à côté de la AWS CLI configuration. Si vous avez un rôle que vous utilisez généralement avec AWS Glue Emplois, ce sera ce rôle. Si vous n'avez pas de rôle que vous utiliserez pour AWS Glue jobs, veuillez suivre ce guide, [Configuration des autorisations IAM pour AWS Glue](#), pour en créer un.

Pour définir ce rôle comme rôle par défaut pour les séances interactives, procédez comme suit :

1. Ouvrez `~/.aws/config` avec un éditeur de texte.

2. Recherchez le profil que vous utilisez pour AWS Glue. Si vous n'utilisez pas de profil, [Default] utilisez-le.
3. Ajoutez une ligne dans le profil pour le rôle que vous avez l'intention d'utiliser comme `glue_role_arn=<AWSGlueServiceRole>`.
4. [Facultatif] : si votre profil ne possède pas de région par défaut, je vous recommande d'en ajouter une avec `region=us-east-1`, en remplaçant `us-east-1` par la région de votre choix.
5. Enregistrez la configuration.

Pour de plus amples informations, veuillez consulter [Séances interactives avec IAM](#).

Instructions Windows

AWS Glue les sessions interactives nécessitent les mêmes autorisations IAM que AWS Glue Emplois et points de terminaison de développement. Spécifiez le rôle utilisé avec des séances interactives de l'une des deux manières suivantes :

1. Avec magics `%iam_role` et `%region`
2. Avec une ligne supplémentaire dans `~/.aws/config`

Configuration d'un rôle de séance avec magic

Dans la première cellule, saisissez `%iam_role <YourGlueServiceRole>` dans la première cellule exécutée.

Configuration d'un rôle de session avec `~/.aws/config`

AWS Glue Le rôle de service pour les sessions interactives peut être spécifié dans le bloc-notes lui-même ou stocké à côté de la AWS CLI configuration. Si vous avez un rôle que vous utilisez généralement avec AWS Glue Emplois, ce sera ce rôle. Si vous n'avez pas de rôle que vous utiliserez pour AWS Glue emplois, veuillez suivre ce guide, [Configuration des autorisations IAM pour AWS Glue](#), pour en créer un.

Pour définir ce rôle comme rôle par défaut pour les séances interactives, procédez comme suit :

1. Ouvrez `~/.aws/config` avec un éditeur de texte.
2. Recherchez le profil que vous utilisez pour AWS Glue. Si vous n'utilisez pas de profil, [Default] utilisez-le.

3. Ajoutez une ligne dans le profil pour le rôle que vous avez l'intention d'utiliser comme `glue_role_arn=<AWSGlueServiceRole>`.
4. [Facultatif] : si votre profil ne possède pas de région par défaut, je vous recommande d'en ajouter une avec `region=us-east-1`, en remplaçant `us-east-1` par la région de votre choix.
5. Enregistrez la configuration.

Pour de plus amples informations, veuillez consulter [Séances interactives avec IAM](#).

Mise à niveau à partir de l'aperçu des séances interactives

Le noyau a été mis à niveau avec de nouveaux noms lors de sa sortie avec la version 0.27. Pour nettoyer les versions d'aperçu des noyaux, exécutez ce qui suit depuis un terminal ou PowerShell.

Note

Si vous faites partie d'un autre AWS Glue aperçu qui nécessite un modèle de service personnalisé, la suppression du noyau supprimera le modèle de service personnalisé.

```
# Remove Old Glue Kernels
jupyter kernelspec remove glue_python_kernel
jupyter kernelspec remove glue_scala_kernel

# Remove Custom Model
cd ~/.aws/models
rm -rf glue/
```

Utilisation de sessions interactives avec SageMaker AI Studio

AWS Glue Interactive Sessions est un environnement d'exécution Apache Spark à la demande, sans serveur, que les data scientists et les ingénieurs peuvent utiliser pour créer, tester et exécuter rapidement des applications de préparation et d'analyse des données. Vous pouvez lancer une session AWS Glue interactive en démarrant un bloc-notes Amazon SageMaker AI Studio Classic.

Pour plus d'informations, voir [Préparer les données à l'aide de AWS Glue sessions interactives](#).

Utilisation des séances interactives avec Microsoft Visual Studio Code

Prérequis

- Installation AWS Glue sessions interactives et vérifiez que cela fonctionne avec Jupyter Notebook.
- Téléchargez et installez Visual Studio Code avec Jupyter. Pour plus d'informations, consultez [Bloc-notes Jupyter dans VS Code](#).


Pour démarrer avec des sessions interactives avec VSCode

1. Désactivez Jupyter AutoStart dans VS Code.


Dans Visual Studio Code, les noyaux Jupyter démarreront automatiquement, ce qui empêchera vos magics de faire effet, car la session sera déjà lancée. Pour désactiver le Démarrage automatique sous Windows, accédez à Fichier > Préférences > Extensions > Jupyter > faites un clic droit sur Jupyter puis choisissez Paramètres d'extension.

Sur macOS, accédez à Code > Paramètres > Extensions > Jupyter > faites un clic droit sur Jupyter puis choisissez Paramètres d'extension.


Faites défiler la page vers le bas jusqu'à ce que vous voyiez Jupyter : désactiver le démarrage automatique de Jupyter. Cochez la case « Lorsque la valeur est vraie, le démarrage automatique de Jupyter est désactivé pour vous. Vous devez plutôt exécuter une cellule pour démarrer Jupyter. »



- ### 2. Accédez à Fichier > Nouveau fichier > Enregistrer pour enregistrer ce fichier avec le nom de votre choix en tant qu'une extension .ipynb ou sélectionnez jupyter sous select a language (Choisissez un langage), puis enregistrez le fichier.



3. Double-cliquez sur le fichier. Le shell Jupyter s'affiche et un bloc-notes s'ouvre.



4. Sous Windows, lorsque vous créez un fichier pour la première fois, par défaut, aucun noyau n'est sélectionné. Cliquez sur Select Kernel (Choisissez un noyau) et une liste des noyaux disponibles s'affiche. Choisissez Glue PySpark.

Sur macOS, si le PySpark noyau Glue n'apparaît pas, essayez les étapes suivantes :

1. Lancez une session Jupyter locale pour obtenir l'URL.

Par exemple, pour lancer le bloc-notes Jupyter, exécutez la commande suivante.

jupyter notebook


Lorsque le bloc-notes s'exécute pour la première fois, vous verrez une URL qui ressemble à `http://localhost:8888/?token=3398XXXXXXXXXXXXXXXXXX`.

Copiez l'URL.


2. Dans VS Code, cliquez sur le noyau actuel, puis sur Sélectionnez un autre noyau..., puis sélectionnez Serveur Jupyter existant.... Collez l'URL que vous avez copiée à l'étape ci-dessus.

Si vous recevez un message d'erreur, consultez le [wiki VS Code Jupyter](#).

3. En cas de succès, le noyau sera défini sur Glue PySpark.



Choisissez le noyau Glue PySpark ou Glue Spark (pour Python et Scala respectivement).



Si vous ne voyez pas AWS Glue PySpark et AWS Glue Les noyaux Spark figurent dans la liste déroulante, veuillez vous assurer que vous avez installé AWS Glue noyau à l'étape ci-dessus, ou que votre `python.defaultInterpreterPath` paramètre dans Visual Studio

Code est correct. Pour plus d'informations, consultez [Python. defaultInterpreterPath description du réglage](#).

5. Créez un AWS Glue Séance interactive. Procédez à la création d'une session de la même manière que dans le bloc-notes Jupyter. Spécifiez n'importe quelle magie en haut de la première cellule et exécutez une instruction de code.

Séances interactives avec IAM

Ces sections décrivent les considérations de sécurité pour AWS Glue sessions interactives.

Rubriques

- [Principaux IAM utilisés avec des séances interactives](#)
- [Paramétrer un client principal](#)
- [Paramétrer un rôle d'exécution](#)
- [Rendez votre session privée avec TagOnCreate](#)
- [Considérations de politique IAM](#)

Principaux IAM utilisés avec des séances interactives

Vous utilisez deux principes IAM utilisés avec AWS Glue sessions interactives.

- Client principal : Le client principal (un utilisateur ou un rôle) autorise les opérations d'API pour les sessions interactives à partir d'un AWS Glue client configuré avec les informations d'identification basées sur l'identité du principal. Par exemple, il peut s'agir d'un rôle IAM que vous utilisez généralement pour accéder au AWS Glue console. Il peut également s'agir d'un rôle attribué à un utilisateur dans IAM dont les informations d'identification sont utilisées pour AWS Command Line Interface, ou AWS Glue client utilisé par les sessions interactives du noyau Jupyter.
- Rôle d'exécution : le rôle d'exécution est un rôle IAM que le client principal transmet aux opérations d'API des sessions interactives. AWS Glue utilise ce rôle pour exécuter des instructions dans votre session. Par exemple, ce rôle peut être celui utilisé pour exécuter AWS Glue Emplois ETL.

Pour de plus amples informations, veuillez consulter [Paramétrer un rôle d'exécution](#).

Paramétrer un client principal

Vous devez attacher une politique d'identité au principal du client pour lui permettre d'appeler l'API des séances interactives. Ce rôle doit avoir un accès `iam:PassRole` au rôle d'exécution que vous devez transmettre aux API des séances interactives telles que `CreateSession`. Par exemple, vous pouvez associer la politique `AWSGlueConsoleFullAccess` gérée à un rôle IAM qui permet aux utilisateurs de votre compte auxquels la politique est attachée d'accéder à toutes les sessions créées dans votre compte (comme la déclaration d'exécution ou la déclaration d'annulation).

Si vous souhaitez protéger votre session et la rendre privée uniquement pour certains rôles IAM, tels que ceux associés à l'utilisateur qui a créé la session, vous pouvez utiliser AWS Glue Le contrôle d'autorisation basé sur les balises de la session interactive a été appelé `TagOnCreate`. Pour plus d'informations, découvrez [Rendez votre session privée avec TagOnCreate](#) comment une politique gérée délimitée basée sur le tag du propriétaire peut rendre votre session privée avec `TagOnCreate`. Pour plus d'informations sur les politiques basées sur l'identité, voir [Politiques basées sur l'identité pour AWS Glue](#).

Paramétrer un rôle d'exécution

Vous devez transmettre un rôle IAM à l'opération `CreateSession` d'API afin d'autoriser AWS Glue pour assumer et exécuter des instructions dans des sessions interactives. Le rôle doit disposer des mêmes autorisations IAM que celles requises pour exécuter un AWS Glue travail. Par exemple, vous pouvez créer un rôle de service à l'aide de la `AWSGlueServiceRole` politique qui permet AWS Glue pour appeler AWS les services en votre nom. Si vous utilisez le plugin AWS Glue console, il créera automatiquement un rôle de service en votre nom ou utilisera un rôle existant. Vous pouvez également créer votre propre rôle IAM et attacher votre propre politique IAM pour autoriser des autorisations similaires.

Si vous souhaitez protéger votre session et la rendre privée uniquement pour l'utilisateur qui l'a créée, vous pouvez utiliser AWS Glue Le contrôle d'autorisation basé sur les balises de la session interactive a été appelé `TagOnCreate`. Pour plus d'informations, découvrez [Rendez votre session privée avec TagOnCreate](#) comment une politique gérée délimitée basée sur le tag du propriétaire peut rendre votre session privée avec `TagOnCreate`. Pour plus d'informations sur les stratégies basées sur l'identité, consultez [Politiques basées sur l'identité pour Glue AWS](#). Si vous créez vous-même le rôle d'exécution à partir de la console IAM et que vous souhaitez rendre votre service privé grâce à `TagOnCreate` une fonctionnalité, suivez les étapes ci-dessous.

1. Créez un rôle IAM avec le type de rôle défini sur `Glue`.
2. Joignez ceci AWS Glue politique gérée : `AwsGlueSessionUserRestrictedServiceRole`

3. Préfixez le nom du rôle par le nom de la politique. `AwsGlueSessionUserRestrictedServiceRole`
Par exemple, vous pouvez créer un rôle avec le nom `AwsGlueSessionUserRestrictedServiceRole-myrole` et attacher AWS Glue politique gérée `AwsGlueSessionUserRestrictedServiceRole`.
4. Joignez une politique de confiance comme la suivante pour autoriser AWS Glue pour assumer le rôle :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": [
          "glue.amazonaws.com"
        ]
      },
      "Action": [
        "sts:AssumeRole"
      ]
    }
  ]
}
```

Pour une session interactive (noyau Jupyter), vous pouvez spécifier la `iam_role` clé dans votre AWS Command Line Interface profil. Pour de plus amples informations, veuillez consulter [Configuration de séances avec ~/.aws/config](#) (langue Français non garantie). Si vous interagissez avec des sessions interactives à l'aide d'un AWS Glue bloc-notes, vous pouvez alors passer le rôle d'exécution dans la `%iam_role` magie dans la première cellule que vous exécutez.

Rendez votre session privée avec TagOnCreate

AWS Glue les sessions interactives prennent en charge le balisage et l'autorisation basée sur les balises (TBAC) pour les sessions interactives en tant que ressource nommée. Outre l'utilisation du TBAC `TagResource` et `UntagResource` APIs AWS Glue les sessions interactives prennent en charge la `TagOnCreate` fonctionnalité permettant de « baliser » une session avec une balise donnée uniquement lors de la création et du `CreateSession` fonctionnement de la session. Cela signifie également que ces balises seront supprimées le `DeleteSession`, c'est-à-dire `UntagOnDelete`.

TagOnCreate propose un puissant mécanisme de sécurité pour rendre votre session privée pour le créateur de la session. Par exemple, vous pouvez associer une politique IAM avec « owner » RequestTag et une valeur de \$ {aws:userId} à un client principal (tel qu'un utilisateur) afin d'autoriser la création d'une session uniquement si une balise « owner » avec la valeur correspondante à l'identifiant de l'appelant est fournie en tant que balise userID dans la demande. CreateSession Cette politique permet AWS Glue sessions interactives pour créer une ressource de session et étiqueter la session avec la balise UserID uniquement pendant la période de création de session. En outre, vous pouvez limiter l'accès (comme l'exécution d'instructions) à votre session uniquement au créateur (c'est-à-dire au tag owner avec la valeur \$ {aws:userId}) de la session en attachant une politique IAM avec « owner » ResourceTag au rôle d'exécution que vous avez transmis au cours de cette session. CreateSession

Afin de faciliter l'utilisation de la TagOnCreate fonctionnalité permettant de rendre une session privée pour le créateur de session, AWS Glue fournit des politiques gérées et des rôles de service spécialisés.

Si vous souhaitez créer un AWS Glue Session interactive utilisant un AssumeRole principal IAM (c'est-à-dire utilisant des informations d'identification fournies en assumant un rôle IAM) et vous souhaitez rendre la session privée pour le créateur, puis utiliser des politiques similaires à celles de et respectivement.

AWSGlueSessionUserRestrictedNotebookPolicyAWSGlueSessionUserRestrictedNotebookServiceRole Ces politiques permettent AWS Glue pour utiliser \$ {aws :PrincipalTag} pour extraire la valeur de la balise du propriétaire. Cela nécessite que vous transmettiez une balise UserID avec la valeur \$ {aws:userId} comme SessionTag dans les informations d'identification du rôle assumé. Voir [Balises d'identification de séance](#) . Si vous utilisez une EC2 instance Amazon avec un profil d'instance fournissant les informations d'identification et que vous souhaitez créer une session ou interagir avec la session depuis l' EC2 instance Amazon, vous devez transmettre une balise userId avec la valeur \$ {aws:userId} comme dans l'identifiant de rôle assumé. SessionTag

Par exemple, si vous créez une session à l'aide d'un identifiant AssumeRole principal IAM et que vous souhaitez rendre votre service privé avec une TagOnCreate fonctionnalité, suivez les étapes ci-dessous.

1. Créez vous-même un rôle d'exécution à partir de la console IAM. Veuillez joindre ceci AWS Glue stratégie gérée AwsGlueSessionUserRestrictedNotebookServiceRoleet préfixez le nom du rôle par le nom de la politique. AwsGlueSessionUserRestrictedNotebookServiceRole Par exemple, vous pouvez créer un rôle avec le nom AwsGlueSessionUserRestrictedNotebookServiceRole-

myrole et attacher AWS Glue politique gérée
 AwsGlueSessionUserRestrictedNotebookServiceRole.

2. Joignez une politique de confiance comme ci-dessous pour autoriser AWS Glue pour assumer le rôle ci-dessus.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": [
          "glue.amazonaws.com"
        ]
      },
      "Action": [
        "sts:AssumeRole"
      ]
    }
  ]
}
```

3. Créez un autre rôle nommé avec un préfixe AwsGlueSessionUserRestrictedNotebookPolicyet attachez le AWS Glue politique gérée AwsGlueSessionUserRestrictedNotebookPolicypour rendre la session privée. Outre la politique gérée, veuillez joindre la politique en ligne suivante pour autoriser iam : au rôle que vous avez créé PassRole à l'étape 1.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "iam:PassRole"
      ],
      "Resource": [
        "arn:aws:iam::*:role/AwsGlueSessionUserRestrictedNotebookServiceRole*"
      ],
      "Condition": {
        "StringLike": {

```

```

        "iam:PassedToService": [
            "glue.amazonaws.com"
        ]
    }
}
]
}

```

4. Associez une politique de confiance telle que la suivante à l'IAM ci-dessus AWS Glue pour assumer le rôle.

```

{
  "Version": "2012-10-17",
  "Statement": [{
    "Effect": "Allow",
    "Principal": {
      "Service": [
        "glue.amazonaws.com"
      ]
    },
    "Action": [
      "sts:AssumeRole",
      "sts:TagSession"
    ]
  }]
}

```

Note

Vous pouvez éventuellement utiliser un seul rôle (par exemple, le rôle `bloc-notes`) et associer les deux politiques gérées ci-dessus `AwsGlueSessionUserRestrictedNotebookServiceRole` et `AwsGlueSessionUserRestrictedNotebookPolicy`. Joignez également la politique en ligne supplémentaire pour permettre à votre rôle `iam:passrole` de AWS Glue. Et enfin, attachez la politique de confiance ci-dessus pour autoriser `sts:AssumeRole` et `sts:TagSession`.

AWSGlueSessionUserRestrictedNotebookPolicy

AWSGlueSessionUserRestrictedNotebookPolicy Permet de créer un AWS Glue Session interactive à partir d'un bloc-notes uniquement si la clé de balise « propriétaire » et la valeur correspondent à l'identifiant AWS utilisateur du principal (utilisateur ou rôle). Pour plus d'informations, consultez [Emplacement où vous pouvez utiliser les variables de politique](#). Cette politique est attachée au principal (utilisateur ou rôle) qui crée AWS Glue Carnets de session interactifs de AWS Glue Studio. Cette politique permet également un accès suffisant au AWS Glue Studio bloc-notes pour interagir avec le AWS Glue Studio Ressources de session interactive créées avec la valeur de balise « owner » correspondant à l'ID AWS utilisateur du principal. Cette politique refuse l'autorisation de modifier ou de supprimer le tag « propriétaire » d'un AWS Glue ressource de session après la création de la session.

AWSGlueSessionUserRestrictedNotebookServiceRole

AWSGlueSessionUserRestrictedNotebookServiceRolell fournit un accès suffisant au AWS Glue Studio bloc-notes pour interagir avec le AWS Glue Ressources de session interactive créées avec la valeur de balise « owner » correspondant à l'ID AWS utilisateur du principal (utilisateur ou rôle) du créateur du bloc-notes. Pour plus d'informations, consultez [Emplacement où vous pouvez utiliser les variables de politique](#). Cette politique de rôle de service est attachée au rôle qui est transmis comme par magie à un bloc-notes ou transmis en tant que rôle d'exécution à l' CreateSession API. Cette politique permet également de créer un AWS Glue Session interactive à partir d'un bloc-notes uniquement si la clé de balise « propriétaire » et la valeur correspondent à AWS l'ID utilisateur du principal. Cette politique refuse l'autorisation de modifier ou de supprimer le tag « propriétaire » d'un AWS Glue ressource de session après la création de la session. Cette politique inclut également les autorisations d'écriture et de lecture à partir de compartiments Amazon S3, de rédaction de CloudWatch journaux, de création et de suppression de balises pour les EC2 ressources Amazon utilisées par AWS Glue.

Rendre votre session privée avec les politiques utilisateur

Vous pouvez associer les rôles IAM AWSGlueSessionUserRestrictedPolicyà chacun des utilisateurs de votre compte pour les empêcher de créer une session uniquement avec un tag de propriétaire dont la valeur correspond à leur propre \$ {aws:userId}. Au lieu d'utiliser le AWSGlueSessionUserRestrictedNotebookPolicyet, AWSGlueSessionUserRestrictedNotebookServiceRolevous devez utiliser des politiques similaires au AWSGlueSessionUserRestrictedPolicyet AWSGlueSessionUserRestrictedServiceRolerespectivement. Pour plus d'informations, consultez [Using-identity based policies](#). Cette politique réduit l'accès à une session uniquement au créateur,

l'`${aws:userId}` de l'utilisateur qui a créé la session avec la balise propriétaire portant son propre `${aws:userId}`. Si vous avez créé vous-même le rôle d'exécution à l'aide de la console IAM en [Paramétrer un rôle d'exécution](#) suivant les étapes décrites dans la section, associez également la politique `AwsGlueSessionUserRestrictedPolicy` gérée ci-dessous à chacun des utilisateurs de votre compte `iam:PassRole` pour autoriser le rôle d'exécution que vous avez créé précédemment.

```
{
  "Version": "2012-10-17",
  "Statement": [{
    "Effect": "Allow",
    "Action": [
      "iam:PassRole"
    ],
    "Resource": [
      "arn:aws:iam::*:role/AwsGlueSessionUserRestrictedServiceRole*"
    ],
    "Condition": {
      "StringLike": {
        "iam:PassedToService": [
          "glue.amazonaws.com"
        ]
      }
    }
  ]
}
```

AWSGlueSessionUserRestrictedPolicy

`AWSGlueSessionUserRestrictedPolicy` Permet de créer un AWS Glue Session interactive utilisant l' `CreateSession` API uniquement si une clé de balise « propriétaire » et une valeur correspondant à son ID AWS utilisateur sont fournies. Cette politique d'identité est attachée à l'utilisateur qui appelle l' `CreateSession` API. Cette politique permet également d'interagir avec AWS Glue Ressources de session interactive créées avec une balise « owner » et une valeur correspondant à leur identifiant AWS utilisateur. Cette politique refuse l'autorisation de modifier ou de supprimer le tag « propriétaire » d'un AWS Glue ressource de session après la création de la session.

AWSGlueSessionUserRestrictedServiceRole

`AWSGlueSessionUserRestrictedServiceRole` Il fournit un accès complet à tous AWS Glue ressources à l'exception des sessions et permet aux utilisateurs de créer et d'utiliser uniquement les sessions interactives associées à l'utilisateur. Cette politique inclut également d'autres autorisations requises

par AWS Glue pour gérer les ressources Glue dans d'autres AWS services. La politique permet également d'ajouter des balises à AWS Glue ressources dans d'autres AWS services.

Considérations de politique IAM

Les sessions interactives sont des ressources IAM dans AWS Glue. Comme il s'agit de ressources IAM, l'accès et l'interaction avec une session sont régis par des politiques IAM. Sur la base des politiques IAM attachées à un client principal ou à un rôle d'exécution configuré par un administrateur, un client principal (utilisateur ou rôle) pourra créer de nouvelles séances et interagir avec ses propres séances et d'autres séances.

Si un administrateur a joint une politique IAM telle que `AWSGlue ConsoleFullAccess` ou `AWSGlue ServiceRole` qui autorise l'accès à tous AWS Glue grâce aux ressources de ce compte, un client principal pourra collaborer entre eux. Par exemple, un utilisateur sera en mesure d'interagir avec des séances créées par d'autres utilisateurs si les politiques l'autorisent.

Si vous souhaitez configurer une politique adaptée à vos besoins spécifiques, veuillez consulter la [documentation IAM sur la configuration des ressources pour une politique](#). Par exemple, afin d'isoler les sessions appartenant à un utilisateur, vous pouvez utiliser la `TagOnCreate` fonctionnalité prise en charge par AWS Glue Sessions interactives. Consultez [Rendez votre session privée avec TagOnCreate](#).

Les sessions interactives prennent en charge la limitation de la création de sessions sur la base de certaines conditions VPC. Consultez [Contrôler des politiques qui contrôlent les paramètres à l'aide des clés de condition](#).

Configuration AWS Glue sessions interactives pour Jupyter et AWS Glue Studio blocs-notes

Présentation de Jupyter magics

Les Jupyter magics sont des commandes qui peuvent être exécutées au début d'une cellule ou en tant que corps cellulaire entier. Les magics commencent par `%` pour les magics linéaires et `%%` pour les magics cellulaires. Les magics linéaires telles que `%region` et `%connections` peuvent être exécutées avec plusieurs magics dans une cellule, ou avec du code inclus à l'intérieur de la cellule, comme dans l'exemple suivant.

```
%region us-east-2
%connections my_rds_connection
```



```
dy_f = glue_context.create_dynamic_frame.from_catalog(database='rds_tables',
table_name='sales_table')
```

Les magics cellulaires doivent utiliser la cellule entière et leur commande peut s'étendre sur plusieurs lignes. Ci-dessous un exemple de `%%sql`.

```
%%sql
select * from rds_tables.sales_table
```

Magics soutenu par AWS Glue sessions interactives pour Jupyter

Voici des magies que vous pouvez utiliser avec AWS Glue sessions interactives pour les blocs-notes Jupyter.

Sessions Magics (Séances Magics)

Nom	Type	Description
<code>%help</code>	N/A	Renvoie une liste de descriptions et de types d'entrée pour toutes les commandes magiques.
<code>%profile</code>	Chaîne	Spécifiez un profil dans votre AWS configuration à utiliser comme fournisseur d'informations d'identification.
<code>%region</code>	Chaîne	Spécifiez le Région AWS ; dans lequel vous souhaitez initialiser une session. Valeurs par défaut de <code>~/ .aws/ configure</code> . Exemple : <code>%region us-west-1</code>
<code>%idle_timeout</code>	Int	Nombre de minutes d'inactivité au bout desquelles une séance expire après l'exécution d'une cellule. La valeur du délai d'inactivité par défaut pour les séances

Nom	Type	Description
		ETL Spark est le délai d'inactivité par défaut, soit 2 880 minutes (48 heures). Pour les autres types de séances, consultez la documentation relative. Exemple : <code>%idle_timeout 3000</code>
<code>%session_id</code>	N/A	Retournez l'ID de séance de la séance en cours d'exécution.
<code>%session_id_prefix</code>	Chaîne	Définissez une chaîne qui précédera toutes les sessions IDs au format [session_id_prefix] - [session_id]. Si aucun ID de séance n'est fourni, un UUID aléatoire est généré. Ce magic n'est pas pris en charge lorsque vous exécutez un bloc-note s Jupyter dans AWS Glue Studio. Exemple : <code>%session_id_prefix 001</code>
<code>%status</code>		Renvoie l'état du courant AWS Glue session, y compris sa durée, sa configuration et son rôle utilisateur/rôle d'exécution.
<code>%stop_session</code>		Arrête la séance en cours.
<code>%list_sessions</code>		Répertorie toutes les séances en cours d'exécution par nom et ID.
<code>%session_type</code>	Chaîne	Définit le type de session comme suit : Streaming, ETL ou Ray. Exemple : <code>%session_type Streaming</code>

Nom	Type	Description
<code>%glue_version</code>	Chaîne	La version de AWS Glue à utiliser lors de cette session. Exemple : <code>%glue_version 3.0</code>

Magics pour la sélection des types de tâches

Nom	Type	Description
<code>%streaming</code>	Chaîne	Modifie le type de session en AWS Glue Diffusion en continu.
<code>%etl</code>	Chaîne	Modifie le type de session en AWS Glue ETL.
<code>%glue_ray</code>	Chaîne	Modifie le type de session en « AWS Glue for Ray ». Découvrez les sessions interactives Magics soutenues par AWS Glue Ray .

AWS Glue pour Spark config magics

Le magic `%%configure` est un dictionnaire au format JSON comprenant tous les paramètres de configuration d'une session. Chaque paramètre peut être spécifié ici ou par magies individuelles.

Nom	Type	Description
<code>%%configure</code>	Dictionnaire	Spécifiez un dictionnaire au format JSON comprenant tous les paramètres de configuration d'une séance. Chaque paramètre peut être spécifié ici ou par magies individuelles. Pour obtenir la liste des paramètres et des exemples d'utilisation <code>%%configu</code>

Nom	Type	Description
		re , voir Arguments du magic cellulaire % %configure .
<code>%iam_role</code>	Chaîne	Spécifiez un ARN de rôle IAM avec lequel exécuter votre séance. Valeurs par défaut de <code>~/.aws/configure</code>. Exemple : <code>%iam_role AWSGlueServiceRole</code>
<code>%number_of_workers</code>	Int	Le nombre d'employés d'un paramètre <code>worker_type</code> défini qui sont alloués lorsqu'une tâche est exécutée. <code>worker_type</code> doit également être défini. La valeur par défaut <code>number_of_workers</code> est 5. Exemple : <code>%number_of_workers 2</code>
<code>%additional_python_modules</code>	Liste	Liste de modules Python supplémentaires séparés par des virgules à inclure dans votre cluster (peut provenir de PyPI ou de S3). Exemple: <code>%additional_python_modules pandas, numpy</code> .

Nom	Type	Description
%%tags	Chaîne	Ajoute des balises à une session. Spécifiez les balises entre crochets {}. Chaque paire de noms de balises est placée entre parenthèses (« ») et séparée par une virgule (,). <pre>%%tags {"billing":"Data-Platform", "team":"analytics"}</pre> Utilisez le magic %status pour afficher les balises associées à la session. <pre>%status</pre> <pre>Session ID: <sessionId> Status: READY Role: <example-role> CreatedOn: 2023-05-26 11:12:17. 056000-07:00 GlueVersion: 3.0 Job Type: glueetl Tags: {'owner':'example-owner', 'team':'analytics', 'billing' :'Data-Platform'} Worker Type: G.4X Number of Workers: 5 Region: us-west-2 Applying the following default arguments: --glue_kernel_version 0.38.0 --enable-glue-datacatalog true Arguments Passed: ['--glue_ kernel_version: 0.38.0', '-- enable-glue-datacatalog: true']</pre>

Nom	Type	Description
%%assume_role	Dictionnaire	Spécifiez un dictionnaire au format JSON ou une chaîne ARN de rôle IAM pour créer une session d'accès intercompte. Exemple avec ARN : <pre>%%assume_role { 'arn:aws:iam::XXXXXXXXXXXX: role/AWSGlueServiceRole' }</pre> Exemple avec informations d'identification : <pre>%%assume_role {{ "aws_access_key_id" = "XXXXXXXXXXXX", "aws_secret_access_key" = "XXXXXXXXXXXX", "aws_session_token" = "XXXXXXXXXXXX" }}</pre>

Arguments du magic cellulaire %%configure

Le magic %%configure est un dictionnaire au format JSON comprenant tous les paramètres de configuration d'une session. Chaque paramètre peut être spécifié ici ou par magies individuelles. Vous trouverez ci-dessous des exemples d'arguments soutenus par le magic cellulaire %%configure. Utilisez le -- préfixe pour les arguments d'exécution spécifiés pour la tâche. Exemple :

```
%%configure
{
  "--user-jars-first": "true",
```

```
--enable-glue-datacatalog": "false"
}
```

Pour plus d'informations sur les paramètres des tâches, consultez [Paramètres des tâches](#).

Configuration de session

Paramètre	Type	Description
max_retries	Int	Nombre maximum de tentatives de cette tâche en cas d'échec. <pre>%%configure { "max_retries": "0" }</pre>
max_concurrent_runs	Int	Nombre maximal d'exécutions simultanées autorisées pour une tâche. Exemple : <pre>%%configure { "max_concurrent_runs": "3" }</pre>

Paramètres de session

Paramètre	Type	Description
--enable-spark-ui	Booléen	Activer l'interface utilisateur Spark pour surveiller et déboguer AWS Glue Emplois ETL. <pre>%%configure</pre>

Paramètre	Type	Description
		<pre>{ "--enable-spark-ui": "true" }</pre>
--spark-event-logs-path	Chaîne	Spécifie un chemin d'accès Amazon S3. Lorsque vous utilisez la fonctionnalité de surveillance de l'interface utilisateur Spark. Exemple : <pre>%%configure { "--spark-event-logs-path": "s3://path/to/event/logs/" }</pre>
--script_location	Chaîne	Spécifie le chemin d'accès S3 à un script qui exécute une tâche. Exemple : <pre>%%configure { "script_location": "s3://new- folder-here" }</pre>

Paramètre	Type	Description
--SECURITY_CONFIGURATION	Chaîne	Le nom d'une configuration AWS Glue de sécurité Exemple : <pre>%%configure { "--security_configuration": { "encryption_type": "kms", "kms_key_id": "YOUR_KMS_KEY_ARN" } }</pre>
--job-language	Chaîne	Langage de programmation des scripts. Accepte la valeur « scala » ou « python ». La valeur par défaut est « python ». Exemple : <pre>%%configure { "--job-language": "scala" }</pre>

Paramètre	Type	Description
<code>--class</code>	Chaîne	La classe Scala qui sert de point d'entrée à votre script Scala. La valeur par défaut est nulle. Exemple : <pre>%%configure { "--class": "className" }</pre>
<code>--user-jars-first</code>	Booléen	Donne la priorité aux fichiers JAR supplémentaires du client dans le chemin de classe. La valeur par défaut est nulle. Exemple : <pre>%%configure { "--user-jars-first": "true" }</pre>
<code>--use-postgres-driver</code>	Booléen	Priorise le pilote JDBC Postgres dans le chemin de classe afin d'éviter tout conflit avec le pilote JDBC. Amazon Redshift La valeur par défaut est nulle. Exemple : <pre>%%configure { "--use-postgres-driver": "true" }</pre>

Paramètre	Type	Description
--extra-files	List(string)	Les chemins Amazon S3 vers des fichiers supplémentaires, tels que des fichiers de configuration qui AWS Glue copie dans le répertoire de travail de votre script avant de l'exécuter. Exemple : <pre>%%configure { "--extra-files": "s3://path/to/ additional/files/" }</pre>
--job-bookmark-option	Chaîne	Contrôle le comportement d'un signet de tâche. Accepte la valeur « job-bookmark-enable », « job-bookmark-disable » ou « job-bookmark-pause ». La valeur par défaut est job-bookmark-disable « ». Exemple : <pre>%%configure { "--job-bookmark-option": "job- bookmark-enable" }</pre>

Paramètre	Type	Description
--TempDir	Chaîne	Spécifie un chemin Amazon S3 vers un compartiment qui peut être utilisé comme répertoire temporaire pour la tâche. La valeur par défaut est nulle. Exemple : <pre>%%configure { "--TempDir": "s3://path/to/temp /dir" }</pre>
--enable-s3-parquet-optimized-committer	Booléen	Active le validateur EMRFS optimisé pour Amazon S3 pour l'écriture de données Parquet dans Amazon S3. La valeur par défaut est « true ». Exemple : <pre>%%configure { "--enable-s3-parquet-optimi zed-committer": "false" }</pre>

Paramètre	Type	Description
<code>--enable-rename-algorithm-v2</code>	Booléen	Définit la version de l'algorithme de renommage EMRFS sur la version 2. La valeur par défaut est « true ». Exemple : <pre>%%configure { "--enable-rename-algorithm-v2": "true" }</pre>
<code>--enable-glue-datacatalog</code>	Booléen	Vous permet d'utiliser AWS Glue Catalogue de données en tant que métastore Apache Spark Hive. Exemple : <pre>%%configure { "--enable-glue-datacatalog": "true" }</pre>
<code>--enable-metrics</code>	Booléen	Permet de collecter des métriques de profilage de tâche pour l'exécution de la tâche. La valeur par défaut est « false ». Exemple : <pre>%%configure { "--enable-metrics": "true" }</pre>

Paramètre	Type	Description
<code>--enable-continuous-cloudwatch-log</code>	Booléen	Permet une journalisation continue en temps réel pour AWS Glue emplois. La valeur par défaut est « false ». Exemple : <pre>%%configure { "--enable-continuous-cloudwatch-log": "true" }</pre>
<code>--enable-continuous-log-filter</code>	Booléen	Spécifie un filtre standard ou aucun filtre lorsque vous créez ou modifiez une tâche activée pour la journalisation continue. La valeur par défaut est « true ». Exemple : <pre>%%configure { "--enable-continuous-log-filter": "true" }</pre>

Paramètre	Type	Description
<code>--continuous-log-stream-prefix</code>	Chaîne	Spécifie un préfixe de flux de Amazon CloudWatch journal personnalisé pour une tâche activée pour la journalisation continue. La valeur par défaut est nulle. Exemple : <pre>%%configure { "--continuous-log-stream-prefix": "prefix" }</pre>
<code>--continuous-log-conversionPattern</code>	Chaîne	Spécifie un modèle de journal de conversion personnalisé pour une tâche activée pour la journalisation en continu. La valeur par défaut est nulle. Exemple : <pre>%%configure { "--continuous-log-conversionPattern": "pattern" }</pre>

Paramètre	Type	Description
--conf	Chaîne	Contrôle les paramètres de configuration de Spark. Elle est destinée aux cas d'utilisation avancés. À utiliser --conf avant chaque paramètre. Exemple : <pre>%%configure { "--conf": "spark.hadoop.hive .metastore.glue.catalogid=1 23456789012 --conf hive.meta store.client.factory.class= com.amazonaws.glue.catalog. metastore.AWSGlueDataCatalo gHiveClientFactory --conf hive.metastore.schema.verif ication=false" }</pre>
timeout	Int	Détermine la durée maximale pendant laquelle la session Spark doit attendre la fin d'une instruction avant de la terminer. <pre>%%configure { "timeout": "30" }</pre>
auto-scaling	Booléen	Détermine s'il faut ou non utiliser l'auto-scaling. <pre>%%configure { "--enable-auto-scaling": "true" }</pre>

Magics de tâches Spark (ETL et streaming)

Nom	Type	Description
<code>%worker_type</code>	Chaîne	Standard, G.1X ou G.2X. <code>number_of_workers</code> doit également être défini. Le paramètre <code>worker_type</code> par défaut est G.1X.
<code>%connections</code>	Liste	Spécifiez une liste de connexions séparées par des virgules à utiliser dans la séance. Exemple : <pre>%connections my_rds_connection dy_f = glue_context.create_dynamic _frame.from_catalog(databas e='rds_tables', table_nam e='sales_table')</pre>
<code>%extra_py_files</code>	Liste	Liste de fichiers Python supplémentaires séparée par des virgules provenant d'Amazon S3.
<code>%extra_jars</code>	Liste	Liste de pots supplémentaires séparés par des virgules à inclure dans le cluster.
<code>%spark_conf</code>	Chaîne	Spécifiez des configurations Spark personnalisées pour votre session. Par exemple, <code>%spark_conf spark.serializer=org.apache.spark.serializer.KryoSerializer</code> .

Magics pour les tâches Ray

Nom	Type	Description
<code>%min_workers</code>	Int	Le nombre minimum de travailleurs alloués à une tâche Ray. Par défaut : 1. Exemple : <code>%min_workers 2</code>
<code>%object_memory_head</code>	Int	Le pourcentage de mémoire disponible sur le nœud principal de l'instance après un démarrage à chaud. Minimum : 0. Maximum : 100. Exemple : <code>%object_memory_head 100</code>
<code>%object_memory_worker</code>	Int	Le pourcentage de mémoire disponible sur le composant master de l'instance après un démarrage à chaud. Minimum : 0. Maximum : 100. Exemple : <code>%object_memory_worker 100</code>

Action Magics (Action Magics)

Nom	Type	Description
<code>%%sql</code>	Chaîne	Exécutez le code SQL. Toutes les lignes après magic <code>%%sql</code> initial comme faisant partie du code SQL. Exemple : <code>%%sql select * from rds_tables.sales_table</code>
<code>%matplotlib</code>	Illustration Matplotlib	Visualisez vos données à l'aide de la bibliothèque Matplotlib.

Nom	Type	Description
		Exemple : <pre>import matplotlib.pyplot as plt # Set X-axis and Y-axis values x = [5, 2, 8, 4, 9] y = [10, 4, 8, 5, 2] # Create a bar chart plt.bar(x, y) # Show the plot %matplotlib plt</pre>
%plotly	Illustration Plotly	Visualisez vos données à l'aide de la bibliothèque Plotly. Exemple : <pre>import plotly.express as px #Create a graphical figure fig = px.line(x=["a","b","c"], y=[1,3,2], title="sample figure") #Show the figure %plotly fig</pre>

Désignation des séances

AWS Glue les sessions interactives sont AWS des ressources qui nécessitent un nom. Les noms doivent être uniques pour chaque session et peuvent être restreints par vos administrateurs IAM. Pour de plus amples informations, veuillez consulter [Séances interactives avec IAM](#). Le noyau Jupyter génère automatiquement des noms de session uniques pour vous. Toutefois, les séances peuvent être nommées manuellement de deux manières :

1. À l'aide du fichier de AWS Command Line Interface configuration situé à l'adresse `~/.aws/config`. Voir [Configuration de la AWS configuration avec le AWS Command Line Interface](#).
2. Utilisation des magics `%session_id_prefix`. Consultez [Magics soutenu par AWS Glue sessions interactives pour Jupyter](#).

Un nom de séance est généré comme suit :

- Lorsque le préfixe et l'identifiant de session sont fournis : le nom de la séance sera `{prefix}-{UUID}`.
- Lorsque rien n'est fourni : le nom de la séance sera `{UUID}`.

Le préfixe des noms de session vous permet de reconnaître votre session lorsque vous la listez dans la console AWS CLI or.

Spécification d'un rôle IAM pour les séances interactives

Vous devez spécifier un rôle AWS Identity and Access Management (IAM) à utiliser avec AWS Glue Code ETL que vous exécutez avec des sessions interactives.

Le rôle nécessite les mêmes autorisations IAM que celles requises pour s'exécuter AWS Glue emplois. Voir [Créer un rôle IAM pour AWS Glue](#) pour plus d'informations sur la création d'un rôle pour AWS Glue emplois et sessions interactives.

Les rôles IAM peuvent être spécifiés de deux manières :

- À l'aide du fichier de AWS Command Line Interface configuration situé à l'adresse `~/.aws/config` (recommandé). Pour de plus amples informations, veuillez consulter [Configuration de séances avec `~/.aws/config`](#) (langue Français non garantie).

Note

Lorsque magic de `%profile` est utilisée, la configuration pour `glue_iam_role` de ce profil est respectée.

- Utilisation du magic `%iam_role`. Pour plus d'informations, consultez [Magics soutenu par AWS Glue sessions interactives pour Jupyter](#).

Configuration des séances avec des profils nommés

AWS Glue les sessions interactives utilisent les mêmes informations d'identification que le AWS Command Line Interface ou boto3, et les sessions interactives respectent et fonctionnent avec des profils nommés tels que ceux AWS CLI trouvés dans `~/.aws/config` (Linux et macOS) ou `%USERPROFILE%\aws\config` (Windows). Pour de plus amples informations, consultez [Using named profiles](#).

Les sessions interactives tirent parti des profils nommés en permettant AWS Glue Rôle de service et préfixe d'ID de session à spécifier dans un profil. Pour configurer un rôle de profil, ajoutez une ligne pour la clé `iam_role` et/ou `session_id_prefix` à votre profil nommé comme indiqué ci-dessous. Le `session_id_prefix` ne nécessite pas de guillemets. Par exemple, si vous souhaitez ajouter un `session_id_prefix`, saisissez la valeur du `session_id_prefix=myprefix`.

```
[default]
region=us-east-1
aws_access_key_id=AKIAIOSFODNN7EXAMPLE
aws_secret_access_key=wJalrXUtnFEMI/K7MDENG/bPxRfiCYEXAMPLEKEY
glue_iam_role=arn:aws:iam::<AccountID>:role/<GlueServiceRole>
session_id_prefix=<prefix_for_session_names>

[user1]
region=eu-west-1
aws_access_key_id=AKIAI44QH8DHBEXAMPLE
aws_secret_access_key=je7MtGbClwBF/2Zp9Utk/h3yCo8nvbEXAMPLEKEY
glue_iam_role=arn:aws:iam::<AccountID>:role/<GlueServiceRoleUser1>
session_id_prefix=<prefix_for_session_names_for_user1>
```

Si vous disposez d'une méthode personnalisée pour générer des informations d'identification, vous pouvez également configurer votre profil pour utiliser le paramètre `credential_process` dans votre fichier `~/.aws/config`. Par exemple :

```
[profile developer]
region=us-east-1
credential_process = "/Users/Dave/generate_my_credentials.sh" --username helen
```

Vous trouverez plus de détails sur la source d'approvisionnement des informations d'identification via le paramètre `credential_process` ici : [Source d'approvisionnement des informations d'identification avec un processus externe](#).

Si une région ou `iam_role` ne sont pas définis dans le profil que vous utilisez, vous devez les spécifier à l'aide des magics `%region` et `%iam_role` dans la première cellule que vous exécutez.

Conversion d'un script ou d'un bloc-notes en AWS Glue tâche

Il existe deux manières de convertir un script ou un bloc-notes en AWS Glue emploi :

- Utilisez `nbconvert` pour convertir votre fichier de document de bloc-notes `.ipynb` Jupyter dans un fichier `.py`. Pour plus d'informations, consultez [nbconvert : Convertir les blocs-notes dans d'autres formats](#).
- Téléchargez le fichier sur AWS Glue Studio Carnets.
 - Dans le volet AWS Glue Studio console, choisissez Jobs dans le menu de navigation.
 - Dans la section Create job (Créer une tâche), choisissez Jupyter notebook (Bloc-notes Jupyter).
 - Dans la section Options, choisissez Upload and edit an existing notebook (Charger et modifier un bloc-notes existant).
 - Sélectionnez Choose file (Choisir un fichier) pour charger un fichier `.ipynb`.

Utilisation des opérations de streaming dans AWS Glue sessions interactives

Changement de type de séance de streaming

Utilisez la commande AWS Glue magie de configuration des sessions interactives `%streaming`, pour définir le travail que vous exécutez et initialiser une session interactive de streaming.

Échantillonnage du flux d'entrée pour un développement interactif

Un outil que nous avons développé pour améliorer l'expérience interactive dans AWS Glue les sessions interactives sont l'ajout d'une nouvelle méthode ci-dessous `GlueContext` pour obtenir un instantané d'un flux dans une statique `DynamicFrame`. `GlueContext` vous permet d'inspecter, d'interagir et de mettre en œuvre votre flux de travail.

Avec l'instance de classe `GlueContext`, vous serez en mesure de localiser la méthode `getSampleStreamingDynamicFrame`. Les arguments requis pour cette méthode sont les suivants :

- `dataFrame`: The Spark Streaming `DataFrame`
- `options` : voir les options disponibles ci-dessous

Les options disponibles sont les suivantes :

- `windowSize` : ceci est également appelé Durée du micro-lot. Ce paramètre déterminera la durée d'attente d'une requête en streaming après le déclenchement du lot précédent. La valeur de ce paramètre doit être inférieure à `pollingTimeInMs`.
- `pollingTimeInMme` : La durée totale pendant laquelle la méthode sera exécutée. Il déclenche au moins un micro-lot pour obtenir des échantillons de registre à partir du flux d'entrée.
- `recordPollingLimit`: Ce paramètre vous permet de limiter le nombre total d'enregistrements que vous allez interroger à partir du flux.
- (Facultatif) Vous pouvez également utiliser `writeStreamFunction` pour appliquer cette fonction personnalisée à chaque fonction d'échantillonnage de registre. Voir ci-dessous des exemples dans Scala et Python.

Scala

```
val sampleBatchFunction = (batchDF: DataFrame, batchId: Long) => {//Optional but  
  you can replace your own foreachBatch function here}  
val jsonString: String = s""""{"pollingTimeInMs": "10000", "windowSize": "5  
  seconds"}"""  
val dynFrame = glueContext.getSampleStreamingDynamicFrame(YOUR_STREAMING_DF,  
  JsonOptions(jsonString), sampleBatchFunction)  
dynFrame.show()
```

Python

```
def sample_batch_function(batch_df, batch_id):  
    //Optional but you can replace your own foreachBatch function here  
    options = {
```

```
        "pollingTimeInMs": "10000",
        "windowSize": "5 seconds",
    }
    glue_context.getSampleStreamingDynamicFrame(YOUR_STREAMING_DF, options,
        sample_batch_function)
```

Note

Lorsque le paramètre `DynFrame` échantillonné est vide, cela peut être causé par certaines des raisons suivantes :

- La source Streaming est définie sur « Dernier » et aucune nouvelle donnée n'a été ingérée pendant la période d'échantillonnage.
- Le temps d'interrogation n'est pas suffisant pour traiter les registres qu'il a ingérés. Les données ne s'afficheront pas à moins que l'ensemble du lot n'ait été traité.

Exécution d'applications de streaming dans des séances interactives

Entrée AWS Glue sessions interactives, vous pouvez exécuter un AWS Glue application de streaming, comme la façon dont vous créeriez une application de streaming dans AWS Glue Console. Étant donné que les séances interactives sont basées sur une séance, la présence d'exceptions dans le moteur d'exécution ne provoque pas l'arrêt de la séance. Nous avons maintenant l'avantage supplémentaire de développer votre fonction par lots de manière itérative. Par exemple :

```
def batch_function(data_frame, batch_id):
    log.info(data_frame.count())
    invalid_method_call()
    glueContext.forEachBatch(frame=streaming_df, batch_function = batch_function, options =
        {**})
```

Dans l'exemple ci-dessus, nous avons inclus une utilisation non valide d'une méthode et, contrairement à la méthode normale AWS Glue les tâches qui quitteront l'ensemble de l'application, le contexte de codage et les définitions de l'utilisateur sont entièrement préservés et la session est toujours opérationnelle. Il n'est pas nécessaire d'amorcer un nouveau cluster et de ré-exécuter toute

la transformation précédente. Cela vous autorise à vous concentrer sur l'itération rapide de vos implémentations de fonctions par lots pour obtenir des résultats souhaitables.

Il est important de noter que la séance interactive évalue chaque instruction de manière bloquante afin que la séance n'exécute qu'une seule instruction à la fois. Étant donné que les requêtes de streaming sont continues et ne se terminent jamais, les séances avec des requêtes de streaming actives ne seront pas en mesure de gérer les instructions de suivi à moins qu'elles ne soient interrompues. Vous pouvez émettre la commande d'interruption directement à partir de Bloc-notes Jupyter et notre noyau s'occupera de l'annulation pour vous.

Prenons l'exemple de la séquence suivante d'instructions qui attendent d'être exécutées :

Statement 1:

```
val number = df.count()  
#Spark Action with deterministic result  
Result: 5
```

Statement 2:

```
streamingQuery.start().awaitTermination()  
#Spark Streaming Query that will be executing continuously  
Result: Constantly updated with each microbatch
```

Statement 3:

```
val number2 = df.count()  
#This will not be executed as previous statement will be running indefinitely
```

Développement et test de scripts AWS de tâches Glue localement

Lorsque vous développez et testez vos scripts de travail AWS Glue for Spark, plusieurs options sont disponibles :

- AWS Console Glue Studio
 - Visual editor (Éditeur visuel)
 - Éditeur de script
 - AWS Carnet Glue Studio
- Sessions interactives
 - Bloc-notes Jupyter

- Image Docker
 - Développement local
 - Développement à distance

Vous pouvez choisir l'une des options ci-dessus en fonction de vos besoins.

Si vous préférez ne pas coder ou moins d'expérience en matière de code, l'éditeur visuel AWS Glue Studio est un bon choix.

Si vous préférez une expérience de bloc-notes interactive, le bloc-notes AWS Glue Studio est un bon choix. Pour plus d'informations, consultez la section [Utilisation de Notebooks avec AWS Glue Studio et AWS Glue](#). Si vous souhaitez utiliser votre propre environnement local, les sessions interactives constituent un bon choix. Pour plus d'informations, consultez la section [Utilisation de sessions interactives avec AWS Glue](#).

Si vous préférez une expérience de local/remote développement, l'image Docker est un bon choix. Cela vous permet de développer et de tester des scripts de travail AWS Glue for Spark où vous le souhaitez, sans encourir de frais liés à AWS Glue.

Si vous préférez le développement local sans Docker, l'installation du répertoire de la bibliothèque AWS Glue ETL localement est un bon choix.

Développement à l'aide AWS de Glue Studio

L'éditeur visuel AWS Glue Studio est une interface graphique qui facilite la création, l'exécution et le suivi de tâches d'extraction, de transformation et de chargement (ETL) dans AWS Glue. Vous pouvez composer visuellement des flux de travail de transformation des données et les exécuter de manière fluide sur le moteur AWS ETL sans serveur basé sur Apache Spark de Glue. Vous pouvez inspecter le schéma et les résultats des données à chaque étape de la tâche. Pour plus d'informations, consultez le [guide de l'utilisateur de AWS Glue Studio](#).

Développement à l'aide de sessions interactives

Les sessions interactives vous permettent de créer et de tester des applications à partir de l'environnement de votre choix. Pour plus d'informations, consultez la section [Utilisation de sessions interactives avec AWS Glue](#).

Développez et testez AWS Glue des jobs localement à l'aide d'une image Docker

Pour une plateforme de données prête à être mise en production, le processus de développement et le CI/CD pipeline de AWS Glue jobs constituent un sujet clé. Vous pouvez développer et tester des AWS Glue tâches de manière flexible dans un conteneur Docker. AWS Glue héberge des images Docker sur Docker Hub pour configurer votre environnement de développement avec des utilitaires supplémentaires. Vous pouvez utiliser votre IDE, bloc-notes ou REPL préféré à l'aide de la bibliothèque AWS Glue ETL. Cette rubrique explique comment développer et tester des jobs de AWS Glue la version 5.0 dans un conteneur Docker à l'aide d'une image Docker.

Images Docker disponibles

Les images Docker suivantes sont disponibles pour AWS Glue [Amazon ECR](#) :

- Pour AWS Glue la version 5.0 : `public.ecr.aws/glue/aws-glue-libs:5`
- Pour AWS Glue la version 4.0 : `public.ecr.aws/glue/aws-glue-libs:glue_libs_4.0.0_image_01`
- Pour AWS Glue la version 3.0 : `public.ecr.aws/glue/aws-glue-libs:glue_libs_3.0.0_image_01`
- Pour AWS Glue la version 2.0 : `public.ecr.aws/glue/aws-glue-libs:glue_libs_2.0.0_image_01`

Note

AWS Glue Les images Docker sont compatibles avec x86_64 et arm64.

Dans cet exemple, nous utilisons `public.ecr.aws/glue/aws-glue-libs:5` et exécutons le conteneur sur une machine locale (Mac, Windows ou Linux). Cette image de conteneur a été testée pour les tâches Spark de la AWS Glue version 5.0. L'image contient les éléments suivants :

- Amazon Linux 2023
- AWS Glue Bibliothèque ETL
- Apache Spark 3.5.4

- Bibliothèques de formats de table ouvertes ; Apache Iceberg 1.7.1, Apache Hudi 0.15.0 et Delta Lake 3.3.0
- AWS Glue Client de catalogue de données
- Amazon Redshift connecteur pour Apache Spark
- Amazon DynamoDB connecteur pour Apache Hadoop

Pour configurer votre conteneur, extrayez l'image de la galerie publique ECR, puis lancez le conteneur. Cette rubrique explique comment exécuter votre conteneur à l'aide des méthodes suivantes, en fonction de vos besoins :

- `spark-submit`
- Coque REPL (pyspark)
- `pytest`
- Code Visual Studio

Prérequis

Avant de commencer, assurez-vous que Docker est installé et que le démon Docker est en cours d'exécution. Pour obtenir des instructions d'installation, consultez la documentation Docker pour [Mac](#) ou [Linux](#). La machine qui exécute le Docker héberge le AWS Glue conteneur. Assurez-vous également que vous disposez d'au moins 7 Go d'espace disque pour l'image sur l'hôte exécutant Docker.

Pour plus d'informations sur les restrictions applicables au développement de AWS Glue code en local, consultez la section [Restrictions de développement locales](#).

Configuration AWS

Pour activer les appels AWS d'API depuis le conteneur, configurez les AWS informations d'identification en suivant les étapes suivantes. Dans les sections suivantes, nous utiliserons ce profil AWS nommé.

1. [Créez un profil AWS nommé](#).
2. Ouvrez cmd sous Windows ou sur un terminal Mac/Linux et exécutez la commande suivante dans un terminal :

```
PROFILE_NAME="<your_profile_name>"
```

Dans les sections suivantes, nous utilisons ce profil AWS nommé.

Si vous utilisez Docker sous Windows, choisissez l'icône Docker (clic droit) et choisissez Basculer vers les conteneurs Linux avant d'extraire l'image.

Exécutez la commande suivante pour extraire l'image depuis ECR Public :

```
docker pull public.ecr.aws/glue/aws-glue-libs:5
```

Exécutez le conteneur

Vous pouvez maintenant exécuter un conteneur en utilisant cette image. Vous pouvez choisir l'une des options suivantes en fonction de vos besoins.

spark-submit

Vous pouvez exécuter un script de AWS Glue tâche en exécutant la spark-submit commande sur le conteneur.

1. Rédigez votre script, enregistrez-le comme `sample.py` dans l'exemple ci-dessous, puis enregistrez-le dans le `/local_path_to_workspace/src/` répertoire à l'aide des commandes suivantes :

```
$ WORKSPACE_LOCATION=/local_path_to_workspace  
$ SCRIPT_FILE_NAME=sample.py  
$ mkdir -p ${WORKSPACE_LOCATION}/src  
$ vim ${WORKSPACE_LOCATION}/src/${SCRIPT_FILE_NAME}
```

2. Ces variables sont utilisées dans la commande docker run ci-dessous. L'exemple de code (`sample.py`) utilisé dans la commande spark-submit ci-dessous est inclus dans l'annexe à la fin de cette rubrique.

Exécutez la commande suivante pour exécuter la commande spark-submit sur le conteneur afin de soumettre une nouvelle application Spark :

```
$ docker run -it --rm \
```

```
-v ~/.aws:/home
/hadoop/.aws \
-v $WORKSPACE_LOCATION:/home/hadoop/workspace/ \
-e AWS_PROFILE=$PROFILE_NAME \
--name glue5_spark_submit \
public.ecr.aws/glue/aws-glue-libs:5 \
spark-submit /home/hadoop/workspace/src/$SCRIPT_FILE_NAME
```

3. (Facultatif) Configurez `spark-submit` pour qu'il corresponde à votre environnement. Par exemple, vous pouvez transmettre vos dépendances à la configuration `--jars`. Pour plus d'informations, consultez la section [Chargement dynamique des propriétés de Spark](#) dans la documentation de Spark.

Shell REPL (Pyspark)

Vous pouvez exécuter le shell REPL (read-eval-print loops) pour le développement interactif. Exécutez la commande suivante pour exécuter la PySpark commande sur le conteneur afin de démarrer le shell REPL :

```
$ docker run -it --rm \
    -v ~/.aws:/home/hadoop/.aws \
    -e AWS_PROFILE=$PROFILE_NAME \
    --name glue5_pyspark \
    public.ecr.aws/glue/aws-glue-libs:5 \
    pyspark
```

Vous verrez le résultat suivant :

```
Python 3.11.6 (main, Jan 9 2025, 00:00:00) [GCC 11.4.1 20230605 (Red Hat 11.4.1-2)] on
linux
Type "help", "copyright", "credits" or "license" for more information.
Setting default log level to "WARN".
To adjust logging level use sc.setLogLevel(newLevel). For SparkR, use
setLogLevel(newLevel).
Welcome to
```

```

      _____
     /  _/  _  _  _  _/  _/  _
    -\  \  _  \  _  \  /  _/  _/
   /_  /  .  _  \  /  _/  _  \
      /  /

```

version 3.5.4-amzn-0

```
Using Python version 3.11.6 (main, Jan 9 2025 00:00:00)
Spark context Web UI available at None
Spark context available as 'sc' (master = local[*], app id = local-1740643079929).
SparkSession available as 'spark'.
>>>
```

Avec ce shell REPL, vous pouvez coder et tester de manière interactive.

Pytest

Pour les tests unitaires, vous pouvez utiliser pytest des scripts de travail AWS Glue Spark. Exécutez les commandes suivantes pour la préparation.

```
$ WORKSPACE_LOCATION=/local_path_to_workspace
$ SCRIPT_FILE_NAME=sample.py
$ UNIT_TEST_FILE_NAME=test_sample.py
$ mkdir -p ${WORKSPACE_LOCATION}/tests
$ vim ${WORKSPACE_LOCATION}/tests/${UNIT_TEST_FILE_NAME}
```

Exécutez la commande suivante à exécuter pytest en utilisant docker run :

```
$ docker run -i --rm \
  -v ~/.aws:/home/hadoop/.aws \
  -v $WORKSPACE_LOCATION:/home/hadoop/workspace/ \
  --workdir /home/hadoop/workspace \
  -e AWS_PROFILE=$PROFILE_NAME \
  --name glue5_pytest \
  public.ecr.aws/glue/aws-glue-libs:5 \
  -c "python3 -m pytest --disable-warnings"
```

Une fois l'exécution des tests unitaires pytest terminée, votre sortie ressemblera à ceci :

```
===== test session starts =====
platform linux -- Python 3.11.6, pytest-8.3.4, pluggy-1.5.0
rootdir: /home/hadoop/workspace
plugins: integration-mark-0.2.0
collected 1 item

tests/test_sample.py . [100%]

===== 1 passed, 1 warning in 34.28s =====
```

Configuration du conteneur pour utiliser Visual Studio Code

Pour configurer le conteneur avec Visual Studio Code, procédez comme suit :

1. Installez Visual Studio Code.
2. Installez [Python](#).
3. Installez [Visual Studio Code Remote - Containers](#)
4. Ouvrez le dossier de l'espace de travail dans Visual Studio Code.
5. Appuyez sur Ctrl+Shift+P (Windows/Linux) ou Cmd+Shift+P (Mac).
6. Tapez Preferences: Open Workspace Settings (JSON).
7. Appuyez sur Entrée.
8. Collez le JSON suivant et enregistrez-le.


```
{
  "python.defaultInterpreterPath": "/usr/bin/python3.11",
  "python.analysis.extraPaths": [
    "/usr/lib/spark/python/lib/py4j-0.10.9.7-src.zip:/usr/lib/spark/python:/usr/
lib/spark/python/lib/",
  ]
}
```

Pour configurer le conteneur :


1. Exécutez le conteneur Docker.

```
$ docker run -it --rm \
  -v ~/.aws:/home/hadoop/.aws \
  -v $WORKSPACE_LOCATION:/home/hadoop/workspace/ \
  -e AWS_PROFILE=$PROFILE_NAME \
  --name glue5_pyspark \
  public.ecr.aws/glue/aws-glue-libs:5 \
  pyspark
```


2. Démarrez Visual Studio Code.
3. Choisissez Remote Explorer (Explorateur distant) dans le menu de gauche, puis amazon/aws-glue-libs:glue_libs_4.0.0_image_01.
4. Cliquez avec le bouton droit de la souris et choisissez Joindre dans la fenêtre actuelle.



5. Si la boîte de dialogue suivante apparaît, choisissez Got it.



6. Ouvrir `/home/hadoop/workspace/`.



7. Créez un AWS Glue PySpark script et choisissez Exécuter.

Vous verrez l'exécution réussie du script.

```

src > sample.py > GluePythonSampleTest > __init__
1 import sys
2 from pyspark.context import SparkContext
3 from awsglue.context import GlueContext
4 from awsglue.job import Job
5 from awsglue.utils import getResolvedOptions
6
7
8 class GluePythonSampleTest:
9     def __init__(self):
10         params = {}
11         if '--JOB_NAME' in sys.argv:
12             params.append('--JOB_NAME')
13         args = getResolvedOptions(sys.argv, params)
14
15         self.context = GlueContext(SparkContext.getOrCreate())
16         self.job = Job(self.context)
17
18         if 'JOB_NAME' in args:
19             jobname = args['JOB_NAME']
20         else:
21             jobname = "test"
22         self.job.init(jobname, args)
23
24     def run(self):
25         dyf = read_json(self.context, "s3://awsglue-datasets/examples/us-legislators/all/persons.json")
26         dyf.printSchema()
27
28         self.job.commit()

```

```

bash-5.2$ /usr/bin/python3.11 /home/hadoop/workspace/src/sample.py
Setting default log level to "WARN".
To adjust logging level use sc.setLogLevel(newLevel). For SparkR, use setLogLevel(newLevel).
25/02/27 10:00:04 WARN Job: Job run ID test is either null or empty or its same as Job name.
SLF4J: Failed to load class "org.slf4j.impl.StaticLoggerBinder".
SLF4J: Defaulting to no-operation (NOP) logger implementation
SLF4J: See http://www.slf4j.org/codes.html#StaticLoggerBinder for further details.
25/02/27 10:00:07 WARN ConfigurationHelper: Option fs.s3a.connection.establish.timeout is too low (5,000 ms). Setting to 15,000 ms instead
root
 |-- family_name: string
 |-- name: string
 |-- links: array
 |    |-- element: struct
 |    |    |-- note: string
 |    |    |-- url: string
 |-- gender: string
 |-- image: string
 |-- identifiers: array
 |    |-- element: struct
 |    |    |-- scheme: string
 |    |    |-- identifier: string
 |-- other_names: array
 |    |-- element: struct
 |    |    |-- lang: string
 |    |    |-- note: string
 |    |    |-- name: string
 |-- sort_name: string
 |-- images: array
 |    |-- element: struct
 |    |    |-- url: string
 |-- given_name: string
 |-- birth_date: string

```

Changements entre l'image Docker AWS Glue 4.0 et AWS Glue 5.0

Les principaux changements entre l'image Docker AWS Glue 4.0 et AWS Glue 5.0 :

- Dans la AWS Glue version 5.0, il existe une seule image de conteneur pour les tâches par lots et les tâches de streaming. Cela diffère de Glue 4.0, où il y avait une image pour le batch et une autre pour le streaming.
- Dans la AWS Glue version 5.0, le nom d'utilisateur par défaut du conteneur est `hadoop`. Dans la AWS Glue version 4.0, le nom d'utilisateur par défaut était `glue_user`.
- Dans la AWS Glue version 5.0, plusieurs bibliothèques supplémentaires, dont Livy JupyterLab et Livy, ont été supprimées de l'image. Vous pouvez les installer manuellement.

- Dans la AWS Glue version 5.0, toutes les bibliothèques Iceberg, Hudi et Delta sont préchargées par défaut, et la variable d'environnement `n'DATALAKE_FORMATS` est plus nécessaire. Avant la AWS Glue version 4.0, la variable d'environnement `DATALAKE_FORMATS` était utilisée pour spécifier les formats de table spécifiques à charger.

La liste ci-dessus est spécifique à l'image Docker. Pour en savoir plus sur les mises à jour AWS Glue 5.0, consultez [Présentation de la AWS Glue version 5.0 pour Apache Spark](#) et [Migration des AWS Glue tâches Spark vers AWS Glue la version 5.0](#).

Considérations

N'oubliez pas que les fonctionnalités suivantes ne sont pas prises en charge lors de l'utilisation de l'image du AWS Glue conteneur pour développer des scripts de travail localement.

- [Signets de tâche](#)
- AWS Glue Rédacteur de parquet ([utilisation du format Parquet dans AWS Glue](#))
- [FillMissingValues transformer](#)
- [FindMatches transformer](#)
- [Lecteur CSV SIMD vectorisé](#)
- La propriété [customJdbcDriverS3Path](#) pour charger le pilote JDBC depuis le chemin Amazon S3
- [AWS Glue Qualité des données](#)
- [Détection des données sensibles](#)
- AWS Lake Formation vente d'informations d'identification basée sur des autorisations

Annexe : Ajout de pilotes JDBC et de bibliothèques Java

Pour ajouter un pilote JDBC qui n'est pas actuellement disponible dans le conteneur, vous pouvez créer un nouveau répertoire sous votre espace de travail avec les fichiers JAR dont vous avez besoin et monter le répertoire dans la commande `/opt/spark/jars/` docker run. Les fichiers JAR `/opt/spark/jars/` situés sous le conteneur sont automatiquement ajoutés à Spark Classpath et pourront être utilisés lors de l'exécution du job.

Par exemple, utilisez la commande docker run suivante pour ajouter des fichiers JAR de pilotes JDBC au shell REPL. PySpark

```
docker run -it --rm \
```

```
-v ~/.aws:/home/hadoop/.aws \
-v $WORKSPACE_LOCATION:/home/hadoop/workspace/ \
-v $WORKSPACE_LOCATION/jars:/opt/spark/jars/ \
--workdir /home/hadoop/workspace \
-e AWS_PROFILE=$PROFILE_NAME \
--name glue5_jdbc \
public.ecr.aws/glue/aws-glue-libs:5 \
pyspark
```

Comme indiqué dans *Considérations*, l'option de `customJdbcDriverS3Path` connexion ne peut pas être utilisée pour importer un pilote JDBC personnalisé depuis Amazon S3 dans des images de AWS Glue conteneur.

Points de terminaison de développement

Note

L'expérience de la console pour les points de terminaison de développement a été supprimée à compter du 31 mars 2023. La création, la mise à jour et la surveillance des points de terminaison de développement sont toujours disponibles via et [API de points de terminaison de développement](#) [AWS Glue CLI](#).

Nous vous recommandons vivement de migrer des points de terminaison de développement vers des séances interactives pour les raisons énumérées ci-dessous. Pour connaître les actions requises en matière de migration des points de terminaison de développement vers des séances interactives, veuillez consulter la rubrique [Migration des points de terminaison de développement vers des séances interactives](#).

Description	Points d'extrémité du développeur	Séances interactives
Prise en charge de la version Glue	Prend en charge AWS Glue versions 0.9 et 1.0	Prend en charge AWS Glue version 2.0 et versions ultérieures
Les points de terminaison de développement ne sont	Les séances interactives ne sont actuellement pas	

Description	Points d'extrémité du développeur	Sessions interactives
désormais pas disponibles dans les régions Asie-Pacifique (Jakarta) (ap-southeast-3), Moyen-Orient (EAU) (me-central-1) Europe (Espagne) (eu-south-2), Europe (Zurich) (eu-central-2) ou dans les autres nouvelles régions.	disponibles dans la région Moyen-Orient (EAU) (me-central-1), mais le seront peut-être ultérieurement.	
Méthode d'accès au cluster Spark	Supporte SSH, le shell REPL, le bloc-notes Jupyter, l'IDE (par exemple) PyCharm	appuis AWS Glue Studio bloc-notes, bloc-notes Jupyter, bloc-notes divers IDEs (par exemple, Visual Studio Code PyCharm) et SageMaker bloc-notes AI
Délai jusqu'à la première requête	La configuration d'un cluster Spark prend 10 à 15 minutes	La configuration d'un cluster Spark éphémère peut prendre jusqu'à 1 minute

Description	Points d'extrémité du développeur	Sessions interactives
Modèle de tarification	AWS frais pour les points de terminaison de développement en fonction de l'heure à laquelle le point de terminaison est provisionné et du nombre de DPU. Les points de terminaison du développement n'arrivent pas à expiration. Un temps de facturation minimal de 10 minutes est calculé pour chaque point de terminaison de développement mis en service. En outre, les AWS frais pour le bloc-notes Jupyter sur les EC2 instances Amazon et les blocs-notes SageMaker AI lorsque vous les configurez avec des points de terminaison de développement.	AWS frais pour les sessions interactives en fonction de la durée pendant laquelle la session est active et du nombre de DPUs. Les sessions interactives ont des délais d'inactivité configurables. AWS Glue Studio les ordinateurs portables fournissent une interface intégrée pour les sessions interactives et sont proposés sans frais supplémentaires. Il existe une durée de facturation minimale d'une minute pour chaque session interactive. AWS Glue Studio les ordinateurs portables fournissent une interface intégrée pour les sessions interactives et sont proposés sans frais supplémentaires.
Expérience de la console	Disponible uniquement via l'interface de ligne de commande et l'API	Disponible via le AWS Glue console, CLI et APIs

Migration des points de terminaison de développement vers des séances interactives

Utilisez la liste de contrôle suivante pour déterminer la méthode appropriée permettant de migrer des points de terminaison de développement vers des séances interactives.

Votre script dépend-il de AWS Glue Fonctionnalités spécifiques à 0.9 ou 1.0 (par exemple, HDFS, YARN, etc.) ?

Si la réponse est oui, voir [Migration AWS Glue emplois pour AWS Glue version 3.0](#). pour savoir comment migrer de Glue 0.9 ou 1.0 vers Glue 3.0 et versions ultérieures.

Quelle méthode vous permet d'accéder à votre point de terminaison de développement ?

Si vous utilisez cette méthode,	Procédez comme suit
SageMaker Carnet AI, bloc-notes Jupyter ou JupyterLab	Migrer vers AWS Glue Studio bloc-notes en téléchargeant <code>.ipynb</code> des fichiers sur Jupyter et en créant un nouveau AWS Glue Studio tâche de bloc-notes en téléchargeant le <code>.ipynb</code> fichier. Vous pouvez également utiliser SageMaker AI Studio et sélectionner AWS Glue noyau.
Zeppelin notebook	Convertissez manuellement le bloc-notes en bloc-notes Jupyter en copiant et collant du code ou automatiquement à l'aide d'un convertisseur tiers tel que <code>ze2nb</code> . Ensuite, utilisez le bloc-note s dans AWS Glue Studio ordinateur portable ou SageMaker AI Studio.
IDE	Voir l'auteur AWS Glue emplois avec PyCharm utilisation AWS Glue sessions interactives , ou Utilisation de sessions interactives avec Microsoft Visual Studio Code .
REPL	Installez le aws-glue-session package en local, puis exécutez la commande suivante : • Pour Python : <code>jupyter console --kernel glue_pyspark</code> • Pour Scala : <code>jupyter console --kernel glue_spark</code>

Si vous utilisez cette méthode,	Procédez comme suit
SSH	Il n'existe pas d'option correspondante sur les séances interactives. Vous pouvez également utiliser une image Docker. Pour en savoir plus, veuillez consulter la rubrique Développement à l'aide d'une image Docker .

Les sections suivantes renseignent sur l'utilisation des points de terminaison du développeur pour développer des tâches dans AWS Glue (version 1.0).

Rubriques

- [Développement de scripts à l'aide de points de terminaison de développement](#)
- [Gestion des blocs-notes](#)

Développement de scripts à l'aide de points de terminaison de développement

Note

Les points de terminaison de développement ne sont pris en charge que pour les versions AWS Glue antérieures à 2.0. Pour un environnement interactif dans lequel vous pouvez créer et tester des scripts ETL, utilisez [Notebooks on AWS Glue Studio](#).

AWS Glue peut créer un environnement, appelé point de terminaison de développement, que vous pouvez utiliser pour développer et tester de manière itérative vos scripts d'extraction, de transformation et de chargement (ETL). Vous pouvez créer, modifier et supprimer des points de terminaison de développement à l'aide du AWS Glue console ou API.

Gestion de votre environnement de développement

Lorsque vous créez un point de terminaison de développement, vous fournissez des valeurs de configuration pour mettre en service l'environnement de développement. Ces valeurs indiquent AWS Glue comment configurer le réseau afin que vous puissiez accéder au point de terminaison en toute sécurité et que le point de terminaison puisse accéder à vos magasins de données.

Vous pouvez alors créer un bloc-notes qui se connecte au point de terminaison et utiliser votre bloc-notes pour créer et tester votre script ETL. Lorsque vous êtes satisfait des résultats de votre processus de développement, vous pouvez créer une tâche ETL qui exécute votre script. Grâce à ce processus, vous pouvez ajouter des fonctions et déboguer vos scripts de manière interactive.

Suivez les didacticiels de cette section pour apprendre à utiliser votre point de terminaison de développement avec des blocs-notes.

Rubriques

- [Flux de travail de point de terminaison de développement](#)
- [Comment ? AWS Glue les terminaux de développement fonctionnent avec les ordinateurs portables SageMaker](#)
- [Ajout d'un point de terminaison de développement](#)
- [Accès à votre point de terminaison de développement](#)
- [Tutoriel : Configuration d'un bloc-notes Jupyter JupyterLab pour tester et déboguer des scripts ETL](#)
- [Tutoriel : Utiliser un bloc-notes SageMaker AI avec votre terminal de développement](#)
- [Didacticiel : Utilisation d'un shell REPL avec votre point de terminaison de développement](#)
- [Tutoriel : Configuration d'un PyCharm environnement professionnel avec un terminal de développement](#)
- [Configuration avancée : partage de points de terminaison de développement entre plusieurs utilisateurs](#)

Flux de travail de point de terminaison de développement

Pour utiliser un AWS Glue point de terminaison de développement, vous pouvez suivre ce flux de travail :

1. Créez un point de terminaison de développement à l'aide de l'API. Ce point de terminaison est lancé dans un Virtual Private Cloud (VPC) avec vos groupes de sécurité définis.
2. L'API interroge le point de terminaison de développement jusqu'à ce qu'il soit alloué et prêt pour le travail. Lorsqu'il est prêt, connectez-vous au terminal de développement en utilisant l'une des méthodes suivantes pour créer et tester AWS Glue scripts.
 - Créez un bloc-notes basé sur l' SageMaker IA dans votre compte. Pour plus d'informations sur la création d'un bloc-notes, consultez [the section called “Création de code avec AWS Glue Studio blocs-notes”](#).

- Ouvrez une fenêtre de terminal pour vous connecter directement à un point de terminaison de développement.
 - Si vous disposez de l'édition professionnelle de l'[IDE JetBrains PyCharm Python](#), connectez-la à un point de développement et utilisez-la pour développer de manière interactive. Si vous insérez pydevd des instructions dans votre script, cela PyCharm peut prendre en charge les points d'arrêt distants.
3. Une fois que vous avez terminé le débogage et les tests sur votre point de terminaison de développement, vous pouvez le supprimer.

Comment ? AWS Glue les terminaux de développement fonctionnent avec les ordinateurs portables SageMaker

L'un des moyens les plus courants d'accéder à vos terminaux de développement consiste à utiliser [Jupyter](#) sur des ordinateurs portables. SageMaker Le bloc-notes Jupyter est une application web open source largement utilisée pour la visualisation, l'analytique, le machine learning, etc. Un AWS Glue SageMaker notebook vous offre une expérience de bloc-notes Jupyter avec AWS Glue points de terminaison du développement. Dans le volet AWS Glue SageMaker notebook, l'environnement de bloc-notes Jupyter est préconfiguré avec [SparkMagic](#) un plugin Jupyter open source permettant de soumettre des tâches Spark à un cluster Spark distant. [Apache Livy](#) est un service qui permet l'interaction avec un cluster Spark distant via une API REST. Dans le volet AWS Glue SageMaker notebook, SparkMagic est configuré pour appeler l'API REST sur un serveur Livy exécuté sur un AWS Glue point de terminaison du développement.

Le flux de texte suivant explique le fonctionnement de chaque composant :

AWS Glue SageMaker carnet : (Jupyter → SparkMagic) → (réseau) → AWS Glue point de terminaison de développement : (Apache Livy → Apache Spark)

Une fois que vous avez exécuté votre script Spark écrit dans chaque paragraphe d'un bloc-notes Jupyter, le code Spark est soumis au serveur Livy via SparkMagic, puis une tâche Spark nommée « Livy-session-n » s'exécute sur le cluster Spark. Cette tâche s'appelle une séance Livy. La tâche Spark sera exécutée pendant que la séance du bloc-notes sera active. La tâche Spark sera terminée lorsque vous arrêterez le noyau Jupyter à partir du bloc-notes ou lorsque la séance aura expiré. Une tâche Spark est lancée par fichier (.ipynb) de bloc-notes.

Vous pouvez utiliser un seul AWS Glue point de terminaison de développement avec plusieurs instances de SageMaker bloc-notes. Vous pouvez créer plusieurs fichiers de bloc-notes dans chaque

instance de SageMaker bloc-notes. Lorsque vous ouvrez un fichier de bloc-notes et que vous exécutez les paragraphes, une session Livy est lancée par fichier de bloc-notes sur le cluster Spark via SparkMagic. Chaque séance Livy correspond à une seule tâche Spark.

Comportement par défaut pour AWS Glue terminaux de développement et blocs-notes SageMaker

Les tâches Spark s'exécutent en fonction de la [configuration Spark](#). Il existe plusieurs manières de définir la configuration de Spark (par exemple, la configuration du cluster Spark, SparkMagic la configuration de Spark, etc.).

Par défaut, Spark alloue des ressources de cluster à une séance Livy en fonction de la configuration du cluster Spark. Dans le volet AWS Glue points de terminaison de développement, la configuration du cluster dépend du type de travailleur. Voici un tableau qui explique les configurations les plus courantes par type de tâche.

	Standard	G.1X	G.2X
<code>spark.driver.memory</code>	5G	10G	20G
<code>spark.executor.memory</code>	5G	10G	20G
<code>spark.executor.cores</code>	4	8	16
<code>spark.dynamicAllocation.enabled</code>	TRUE	TRUE	TRUE

Le nombre maximum de programmes d'exécution Spark est calculé automatiquement par combinaison de DPU (ou NumberOfWorkers) et de type de processus.

	Standard	G.1X	G.2X
Nombre maximal de programmes d'exécution Spark	$(\text{DPU} - 1) * 2 - 1$	$(\text{NumberOfWorkers} - 1)$	$(\text{NumberOfWorkers} - 1)$

Par exemple, si votre point de terminaison de développement a 10 processus et que le type de processus est G.1X, alors vous aurez 9 programmes d'exécution Spark et l'ensemble du cluster aura 90 Go de mémoire d'exécuteur puisque chaque exécuteur aura 10 Go de mémoire.

Quel que soit le type de nœud de processus spécifié, l'allocation dynamique des ressources Spark sera activée. Si un jeu de données est suffisamment volumineux, Spark peut allouer tous les programmes d'exécution à une seule séance Livy, car `spark.dynamicAllocation.maxExecutors` n'est pas défini par défaut. Cela signifie que d'autres séances Livy sur le même point de terminaison de développement attendront le lancement de nouveaux programmes d'exécution. Si le jeu de données est peu volumineux, Spark pourra allouer des programmes d'exécution à plusieurs séances Livy en même temps.

Note

Pour plus d'informations sur la façon dont les ressources sont allouées dans différents cas d'utilisation et sur la façon dont vous définissez une configuration pour modifier le comportement, consultez [Configuration avancée : partage de points de terminaison de développement entre plusieurs utilisateurs](#).

Ajout d'un point de terminaison de développement

Utilisez les points de terminaison de développement pour développer et tester de manière itérative vos scripts d'extraction, de transformation et de chargement (ETL) dans AWS Glue. L'utilisation des points de terminaison de développement n'est disponible que via le AWS Command Line Interface.

1. Dans une fenêtre de ligne de commande, entrez une commande similaire à ce qui suit.

```
aws glue create-dev-endpoint --endpoint-name "endpoint1" --role-arn  
"arn:aws:iam::account-id:role/role-name" --number-of-nodes "3" --glue-version  
"1.0" --arguments '{"GLUE_PYTHON_VERSION": "3"}' --region "region-name"
```

Cette commande spécifie AWS Glue version 1.0. Comme cette version prend en charge Python 2 et Python 3, vous pouvez utiliser le paramètre `arguments` pour indiquer la version Python souhaitée. Si le `glue-version` paramètre est omis, AWS Glue la version 0.9 est supposée. Pour plus d'informations sur AWS Glue versions, voir le [Glue version job property](#).

Pour plus d'informations sur les paramètres de ligne de commande supplémentaires, reportez-vous [create-dev-endpoint](#) à la référence des AWS CLI commandes.

2. (Facultatif) Entrez la commande suivante pour vérifier le statut du point de terminaison de développement. Lorsque le statut passe à READY, le point de terminaison de développement est prêt à être utilisé.

```
aws glue get-dev-endpoint --endpoint-name "endpoint1"
```

Accès à votre point de terminaison de développement

Lorsque vous créez un point de terminaison de développement dans un cloud privé virtuel (VPC), AWS Glue renvoie uniquement une adresse IP privée. Le champ de l'adresse IP publique n'est pas renseigné. Lorsque vous créez un point de terminaison de développement non VPC, AWS Glue renvoie uniquement une adresse IP publique.

Si votre point de terminaison de développement possède une adresse publique, vérifiez qu'elle est accessible avec la clé privée SSH pour le point de terminaison de développement, comme dans l'exemple suivant.

```
ssh -i dev-endpoint-private-key.pem glue@public-address
```

Supposons que votre point de terminaison de développement possède une adresse privée, que votre sous-réseau VPC soit routable à partir de l'Internet public et que ses groupes de sécurité autorisent l'accès entrant depuis votre client. Dans ce cas, suivez les étapes ci-dessous pour attacher une adresse IP Elastic à un point de terminaison de développement afin d'autoriser l'accès depuis Internet.

 Note

Pour utiliser des adresses IP Elastic, le sous-réseau utilisé nécessite une passerelle Internet associée via la table de routage.

Pour accéder à un point de terminaison de développement en attachant une adresse IP Elastic

1. Ouvrez la AWS Glue console à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sélectionnez Dev endpoints (Points de terminaison de dev.) et accédez à la page des détails des points de terminaison de développement. Enregistrez l'adresse privée pour l'utiliser à l'étape suivante.
3. Ouvrez la EC2 console Amazon à l'adresse <https://console.aws.amazon.com/ec2/>.
4. Dans le panneau de navigation, sous Network & Security (Réseau et sécurité), choisissez Network Interfaces (Interfaces réseau).
5. Recherchez le DNS privé (IPv4) qui correspond à l'adresse privée sur le AWS Glue page détaillée du point de terminaison de développement de la console.

Vous devrez peut-être modifier les colonnes affichées sur votre EC2 console Amazon. Notez l'ID d'interface réseau (ENI) de cette adresse (par exemple, `eni-12345678`).

6. Sur la EC2 console Amazon, sous Réseau et sécurité, sélectionnez Elastic IPs.
7. Choisissez Allocate new address (Allouer une nouvelle adresse), puis Allocate (Allouer) pour allouer une nouvelle adresse IP Elastic.
8. Sur la IPs page Elastic, choisissez la nouvelle adresse IP Elastic allouée. Puis, choisissez Actions, Associate Address (Associer l'adresse).
9. Dans la page Associer l'adresse, procédez comme suit :
 - Pour Resource type (Type de ressource), choisissez Network interface (Interface réseau).
 - Dans la zone Interface réseau, entrez l'ID d'interface réseau (ENI) de l'adresse privée.
 - Choisissez Associer.
10. Vérifiez que l'adresse IP Elastic nouvellement associée est accessible avec la clé privée SSH associée au point de terminaison de développement, comme dans l'exemple suivant.

```
ssh -i dev-endpoint-private-key.pem glue@elastic-ip
```

Pour plus d'informations sur l'utilisation d'un hôte bastion pour obtenir un accès SSH à l'adresse privée du point de terminaison de développement, consultez le billet de blog sur la AWS sécurité [Connectez-vous en toute sécurité aux instances Linux exécutées dans un Amazon VPC](#) privé.

Tutoriel : Configuration d'un bloc-notes Jupyter JupyterLab pour tester et déboguer des scripts ETL

Dans ce didacticiel, vous allez connecter un bloc-notes Jupyter en JupyterLab cours d'exécution sur votre machine locale à un point de terminaison de développement. Vous procédez ainsi afin de pouvoir exécuter, déboguer et tester de manière interactive AWS Glue extrayez, transformez et chargez des scripts (ETL) avant de les déployer. Ce didacticiel utilise la redirection de port Secure Shell (SSH) pour connecter votre machine locale à un AWS Glue point final de développement. Pour plus d'informations, consultez la page Wikipedia [Redirection de port](#).

Étape 1 : Installation JupyterLab et Sparkmagic

Vous pouvez effectuer l'installation JupyterLab en utilisant conda ou pip. conda est un système de gestion de paquets open source et un système de gestion d'environnement qui fonctionne sous Windows, macOS et Linux. pip est le programme d'installation du package pour Python.

Si vous effectuez l'installation sur macOS, vous devez avoir installé Xcode avant de pouvoir installer Sparkmagic.

1. Installez JupyterLab, Sparkmagic et les extensions associées.

```
$ conda install -c conda-forge jupyterlab
$ pip install sparkmagic
$ jupyter nbextension enable --py --sys-prefix widgetsnbextension
$ jupyter labextension install @jupyter-widgets/jupyterlab-manager
```

2. Vérifiez le répertoire sparkmagic depuis Location.

```
$ pip show sparkmagic | grep Location
Location: /Users/username/.pyenv/versions/anaconda3-5.3.1/lib/python3.7/site-packages
```

3. Remplacez votre répertoire par celui renvoyé pour Location, et installez les noyaux pour Scala et PySpark


```
$ cd /Users/username/.pyenv/versions/anaconda3-5.3.1/lib/python3.7/site-packages
$ jupyter-kernelspec install sparkmagic/kernels/sparkkernel
$ jupyter-kernelspec install sparkmagic/kernels/pysparkkernel
```

4. Télécharger un exemple de fichier config

```
$ curl -o ~/.sparkmagic/config.json https://raw.githubusercontent.com/jupyter-incubator/sparkmagic/master/sparkmagic/example_config.json
```

Dans ce fichier de configuration, vous pouvez configurer les paramètres liés à Spark tels que `driverMemory` et `executorCores`.

Étape 2 : Démarrer JupyterLab

Lorsque vous démarrez JupyterLab, votre navigateur Web par défaut s'ouvre automatiquement et l'URL `http://localhost:8888/lab/workspaces/{workspace_name}` s'affiche.

```
$ jupyter lab
```

Étape 3 : lancer le transfert de port SSH pour vous connecter à votre point de terminaison de développement

Ensuite, utilisez la redirection de port local SSH pour transférer un port local (ici, 8998) vers la destination distante définie par AWS Glue (169.254.76.1:8998).

1. Ouvrez une fenêtre de terminal séparée qui vous donne accès à SSH. Dans Microsoft Windows, vous pouvez utiliser le shell BASH fourni par [Git pour Windows](#) ou installer [Cygwin](#).
2. Exécutez la commande SSH suivante, modifiée comme suit :
 - Remplacez *private-key-file-path* par un chemin vers le fichier .pem qui contient la clé privée correspondant à la clé publique que vous avez utilisée pour créer le point de terminaison de développement.
 - Si vous réacheminez un autre port que 8998, remplacez 8998 par le numéro de port que vous utilisez localement. L'adresse, 169.254.76.1:8998, est le port distant et vous ne la modifiez pas.
 - Remplacez *dev-endpoint-public-dns* par l'adresse DNS publique du point de terminaison de développement. Pour trouver cette adresse, accédez à votre point de

terminaison de développement dans le AWS Glue console, choisissez le nom et copiez l'adresse publique répertoriée sur la page de détails du point de terminaison.

```
ssh -i private-key-file-path -NTL 8998:169.254.76.1:8998 glue@dev-endpoint-public-dns
```

Vous verrez probablement un message d'avertissement, tel que le suivant :

```
The authenticity of host 'ec2-xx-xxx-xxx-xx.us-west-2.compute.amazonaws.com
(xx.xxx.xxx.xx)'
can't be established. ECDSA key fingerprint is SHA256:4e97875Brt+1wKzRko
+Jf1Snp21X7aTP3BcFnHYLEts.
Are you sure you want to continue connecting (yes/no)?
```

Entrez **yes** et laissez la fenêtre du terminal ouverte pendant que vous l'utilisez JupyterLab.

3. Vérifiez que le réacheminement du port SSH fonctionne correctement avec le point de terminaison de développement.

```
$ curl localhost:8998/sessions
{"from":0,"total":0,"sessions":[]}
```

Étape 4 : exécuter un fragment de script simple dans un paragraphe de bloc-notes

Votre bloc-notes JupyterLab devrait désormais fonctionner avec votre terminal de développement. Saisissez le fragment de script ci-après dans votre bloc-notes et exécutez-le.

1. Vérifiez que Spark fonctionne correctement. La commande suivante demande à Spark de calculer 1, puis d'imprimer la valeur.

```
spark.sql("select 1").show()
```

2. Vérifiez si AWS Glue Data Catalog l'intégration fonctionne. La commande suivante répertorie les tables de Data Catalog.

```
spark.sql("show tables").show()
```

3. Vérifiez qu'un simple fragment de script qui utilise AWS Glue les bibliothèques fonctionnent.

Le script suivant utilise les métadonnées de la table `persons_json` dans AWS Glue Data Catalog pour créer un `DynamicFrame` à partir de vos exemples de données. Il affiche ensuite le nombre d'éléments et le schéma des données.

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create a Glue context
glueContext = GlueContext(SparkContext.getOrCreate())

# Create a DynamicFrame using the 'persons_json' table
persons_DyF = glueContext.create_dynamic_frame.from_catalog(database="legislators",
    table_name="persons_json")

# Print out information about *this* data
print("Count: ", persons_DyF.count())
persons_DyF.printSchema()
```

La sortie du script est la suivante.

```
Count: 1961
root
|-- family_name: string
|-- name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- other_names: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- name: string
|   |   |-- lang: string
```

```
|-- sort_name: string
|-- images: array
|   |-- element: struct
|   |   |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|   |-- element: struct
|   |   |-- type: string
|   |   |-- value: string
|-- death_date: string
```

Résolution des problèmes

- Au cours de l'installation de JupyterLab, si votre ordinateur se trouve derrière un proxy ou un pare-feu d'entreprise, vous risquez de rencontrer des erreurs HTTP et SSL en raison de profils de sécurité personnalisés gérés par les services informatiques de l'entreprise.

Voici un exemple d'erreur typique qui se produit lorsque conda ne peut pas se connecter à ses propres référentiels :

```
CondaHTTPError: HTTP 000 CONNECTION FAILED for url <https://repo.anaconda.com/pkgs/
main/win-64/current_repodata.json>
```

Cela peut se produire parce que votre entreprise peut bloquer les connexions aux référentiels les plus utilisés en Python et dans JavaScript les communautés. Pour plus d'informations, consultez la section [Problèmes d'installation](#) sur le JupyterLab site Web.

- Si vous obtenez un message d'erreur connection refused (connexion refusée) lorsque vous essayez de vous connecter à votre point de terminaison de développement, vous utilisez peut-être un point de terminaison de développement obsolète. Essayez de créer un nouveau point de terminaison de développement et de vous reconnecter.

Tutoriel : Utiliser un bloc-notes SageMaker AI avec votre terminal de développement


Entrée AWS Glue, vous pouvez créer un point de terminaison de développement, puis créer un bloc-notes d' SageMaker IA pour vous aider à développer vos scripts ETL et d'apprentissage automatique. Un bloc-notes SageMaker AI est une instance de calcul d'apprentissage automatique entièrement gérée qui exécute l'application Jupyter Notebook.

1. Dans le volet AWS Glue console, choisissez Dev endpoints pour accéder à la liste des endpoints de développement.
2. Cochez la case à côté du nom du point de terminaison de développement que vous souhaitez utiliser, puis dans le menu Action, choisissez Créer un SageMaker bloc-notes.
3. Complétez la page Create and configure a notebook (Créer et configurer un bloc-notes) comme suit :
 - a. Entrez un nom de bloc-notes.
 - b. Sous Attach to development endpoint (Attacher au point de terminaison de développement), vérifiez le point de terminaison de développement.
 - c. Créez ou choisissez un rôle AWS Identity and Access Management (IAM).

La création d'un rôle est recommandée. Si vous utilisez un rôle existant, assurez-vous qu'il dispose des autorisations requises. Pour plus d'informations, consultez [the section called "Étape 6 : créer une politique IAM pour les ordinateurs portables dotés d' SageMaker intelligence artificielle"](#).

- d. (Facultatif) Choisissez un VPC, un sous-réseau et un ou plusieurs groupes de sécurité.
 - e. (Facultatif) Choisissez une clé AWS Key Management Service de chiffrement.
 - f. (Facultatif) Ajoutez des balises pour l'instance de bloc-notes.
4. Choisissez Create Notebook (Créer un bloc-notes). Sur la page Notebooks (Bloc-notes), choisissez l'icône d'actualisation en haut à droite, puis continuez jusqu'à ce que l'état Ready s'affiche.
5. Sélectionnez la case à cocher en regard du nom du nouveau bloc-notes, puis choisissez Open notebook (Ouvrir le bloc-notes).
6. Créez un nouveau bloc-notes : sur la page Jupyter, choisissez Nouveau, puis Sparkmagic (). PySpark

Votre écran doit maintenant avoir l'aspect suivant :



7. (Facultatif) En haut de la page, choisissez Untitled (Sans titre), et donnez un nom au bloc-notes.
8. Pour démarrer une application Spark, entrez la commande suivante dans le bloc-notes, puis dans la barre d'outils, choisissez Run (Exécuter).

```
spark
```

Après un court délai, vous devriez voir la réponse suivante :

```
In [1]: spark
Starting Spark application
```

ID	YARN Application ID	Kind	State	Spark UI	Driver log	Current session?
0	application_1576209965005_0001	pyspark	idle	Link	Link	✓

```
SparkSession available as 'spark'.
<pyspark.sql.session.SparkSession object at 0x7f3d54913550>
```

9. Créez un cadre dynamique et exécutez une requête sur celui-ci : copiez, collez et exécutez le code suivant, qui génère le nombre et le schéma de la table persons_json.

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.transforms import *
glueContext = GlueContext(SparkContext.getOrCreate())
persons_DyF = glueContext.create_dynamic_frame.from_catalog(database="legislators",
    table_name="persons_json")
print ("Count: ", persons_DyF.count())
```

```
persons_DyF.printSchema()
```

Didacticiel : Utilisation d'un shell REPL avec votre point de terminaison de développement

Entrée AWS Glue, vous pouvez créer un point de terminaison de développement, puis invoquer un shell REPL (Read—Evaluate—Print Loop) pour exécuter le PySpark code de manière incrémentielle afin de pouvoir déboguer de manière interactive vos scripts ETL avant de les déployer.

Pour utiliser un REPL sur un point de terminaison de développement, vous devez être autorisé à accéder au point de terminaison par SSH.

1. Sur votre ordinateur local, ouvrez une fenêtre de terminal pouvant exécuter des commandes SSH, et collez-y la commande SSH modifiée. Exécutez la commande .

En supposant que vous ayez accepté AWS Glue version 1.0 avec Python 3 comme point de terminaison de développement, le résultat ressemblera à ceci :

```
Python 3.6.8 (default, Aug  2 2019, 17:42:44)
[GCC 4.8.5 20150623 (Red Hat 4.8.5-28)] on linux
Type "help", "copyright", "credits" or "license" for more information.
SLF4J: Class path contains multiple SLF4J bindings.
SLF4J: Found binding in [jar:file:/usr/share/aws/glue/etl/jars/glue-assembly.jar!/
org/slf4j/impl/StaticLoggerBinder.class]
SLF4J: Found binding in [jar:file:/usr/lib/spark/jars/slf4j-log4j12-1.7.16.jar!/
org/slf4j/impl/StaticLoggerBinder.class]
SLF4J: See http://www.slf4j.org/codes.html#multiple_bindings for an explanation.
SLF4J: Actual binding is of type [org.slf4j.impl.Log4jLoggerFactory]
Setting default log level to "WARN".
To adjust logging level use sc.setLogLevel(newLevel). For SparkR, use
setLogLevel(newLevel).
2019-09-23 22:12:23,071 WARN [Thread-5] yarn.Client (Logging.scala:logWarning(66))
- Neither spark.yarn.jars nor spark.yarn.archive is set, falling back to uploading
libraries under SPARK_HOME.
2019-09-23 22:12:26,562 WARN [Thread-5] yarn.Client (Logging.scala:logWarning(66))
- Same name resource file:/usr/lib/spark/python/lib/pyspark.zip added multiple
times to distributed cache
2019-09-23 22:12:26,580 WARN [Thread-5] yarn.Client (Logging.scala:logWarning(66))
- Same path resource file:///usr/share/aws/glue/etl/python/PyGlue.zip added
multiple times to distributed cache.
```

```

2019-09-23 22:12:26,581 WARN [Thread-5] yarn.Client (Logging.scala:logWarning(66))
- Same path resource file:///usr/lib/spark/python/lib/py4j-src.zip added multiple
times to distributed cache.
2019-09-23 22:12:26,581 WARN [Thread-5] yarn.Client (Logging.scala:logWarning(66))
- Same path resource file:///usr/share/aws/glue/libs/pyspark.zip added multiple
times to distributed cache.
Welcome to

  _ _ _ _ _
 / _ \ _ _ _ _ \ _ \
 _ \ V _ \ _ \ _ \ _ \
/_ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \
/_ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \
/_ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \ _ \

version 2.4.3

Using Python version 3.6.8 (default, Aug 2 2019 17:42:44)
SparkSession available as 'spark'.
>>>

```

2. Vérifiez que le shell de la boucle REPL fonctionne correctement en tapant la déclaration, `print(spark.version)`. Si la version Spark s'affiche, votre REPL est prêt à être utilisé.
3. Vous pouvez maintenant essayer d'exécuter le script simple suivant, ligne par ligne, dans le shell :

```

import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.transforms import *
glueContext = GlueContext(SparkContext.getOrCreate())
persons_DyF = glueContext.create_dynamic_frame.from_catalog(database="legislators",
    table_name="persons_json")
print ("Count: ", persons_DyF.count())
persons_DyF.printSchema()

```

Tutoriel : Configuration d'un PyCharm environnement professionnel avec un terminal de développement

Ce didacticiel explique comment connecter l'IDE Python [PyCharm professionnel](#) exécuté sur votre machine locale à un point de développement afin de pouvoir exécuter, déboguer et tester de manière interactive AWS Glue Scripts ETL (extraction, transfert et chargement) avant de les déployer. Les instructions et les captures d'écran du didacticiel sont basées sur la version PyCharm professionnelle 2019.3.

Pour vous connecter à un point de développement de manière interactive, PyCharm Professional doit être installé sur votre ordinateur. Vous ne pouvez pas le faire avec la version gratuite.

Note

Le didacticiel utilise Amazon S3 comme source de données. Si vous souhaitez utiliser une source de données JDBC à la place, vous devez exécuter votre point de terminaison de développement dans un cloud privé virtuel (VPC). Pour vous connecter avec SSH à un point de terminaison de développement dans un VPC, vous devez créer un tunnel SSH. Ce didacticiel ne contient pas d'instructions pour la création d'un tunnel SSH. Pour plus d'informations sur l'utilisation de SSH pour se connecter à un point de terminaison de développement dans un VPC, consultez la [section Connexion sécurisée aux instances Linux exécutées dans un Amazon VPC privé](#) sur le blog de sécurité. AWS

Rubriques

- [Connecter un PyCharm professionnel à un terminal de développement](#)
- [Déploiement du script sur votre point de terminaison de développement](#)
- [Configuration d'un interpréteur distant](#)
- [Exécution de votre script sur le point de terminaison de développement](#)

Connecter un PyCharm professionnel à un terminal de développement

1. Créez un nouveau projet en Python pur dans named. PyCharm legislators
2. Créez un fichier nommé `get_person_schema.py` dans le projet avec le contenu suivant :

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext

def main():
    # Create a Glue context
    glueContext = GlueContext(SparkContext.getOrCreate())

    # Create a DynamicFrame using the 'persons_json' table
    persons_DyF =
    glueContext.create_dynamic_frame.from_catalog(database="legislators",
    table_name="persons_json")
```

```
# Print out information about this data
print("Count: ", persons_DyF.count())
persons_DyF.printSchema()

if __name__ == "__main__":
    main()
```


3. Effectuez l'une des actions suivantes :

- Dans AWS Glue version 0.9, téléchargez le AWS Glue Fichier de bibliothèque PythonPyGlue.zip, depuis <https://s3.amazonaws.com/aws-glue-jes-prod-us-east-1-assets/etl/python/PyGlue.zip> un emplacement pratique sur votre machine locale.
- Dans AWS Glue version 1.0 et versions ultérieures, téléchargez le AWS Glue Fichier de bibliothèque PythonPyGlue.zip, depuis <https://s3.amazonaws.com/aws-glue-jes-prod-us-east-1-assets/etl-1.0/python/PyGlue.zip> un emplacement pratique sur votre machine locale.

4. Ajoutez PyGlue.zip en tant que racine de contenu pour votre projet dans PyCharm :

- Dans PyCharm, choisissez Fichier, Paramètres pour ouvrir la boîte de dialogue Paramètres. (Vous pouvez également appuyer sur Ctrl+Alt+S.)
- Développez le projet legislators et choisissez Project Structure (Structure du projet). Ensuite, dans le panneau droit, sélectionnez + Add Content Root (+ Ajouter le contenu racine).
- Accédez à l'emplacement où vous avez enregistré PyGlue.zip, sélectionnez-le, puis choisissez Apply (Appliquer).

L'écran Settings (Paramètres) doit ressembler à ceci :



Laissez la boîte de dialogue Settings (Paramètres) ouverte après avoir choisi Apply (Appliquer).


5. Configurez les options de déploiement pour télécharger le script local sur votre terminal de développement à l'aide du protocole SFTP (cette fonctionnalité n'est disponible que dans PyCharm Professional) :
 - Dans la boîte de dialogue Settings (Paramètres), développez la section Build, Execution, Deployment (Création, exécution, déploiement). Choisissez la sous-section Deployment (Déploiement).
 - Sélectionnez l'icône + en haut du panneau central pour ajouter un nouveau serveur. Définissez Type sur SFTP et donnez-lui un nom.
 - Définissez SFTP host (Hôte SFTP) sur l'adresse publique de votre point de terminaison de développement, comme indiqué sur sa page de détails. (Choisissez le nom de votre point de terminaison de développement dans le AWS Glue console pour afficher la page de détails). Pour un point de terminaison de développement s'exécutant dans un VPC, définissez SFTP host (Hôte SFTP) sur l'adresse hôte et le port local de votre tunnel SSH sur le point de terminaison de développement.
 - Définissez le champ User name (Nom d'utilisateur) sur glue.
 - Définissez le champ Auth type (Type d'autorisation) sur Key pair (OpenSSH or Putty) (Paire de clés (OpenSSH ou Putty)). Définissez le champ Private key file (Fichier de clé privée) en accédant à l'emplacement du fichier de clé privée de votre point de terminaison de

développement. Notez que PyCharm seuls les types de clés DSA, RSA et ECDSA OpenSSH sont pris en charge et que les clés au format privé de Putty ne sont pas acceptées. Vous pouvez utiliser une up-to-date version de ssh-keygen pour générer un type de paire de clés qui PyCharm accepte, en utilisant une syntaxe similaire à la suivante :

```
ssh-keygen -t rsa -f <key_file_name> -C "<your_email_address>"
```

- Choisissez Test connection (Tester la connexion) et autorisez le test de la connexion. Si la connexion est établie, choisissez Apply (Appliquer).

L'écran Settings (Paramètres) doit désormais ressembler à ceci :




Laissez à nouveau la boîte de dialogue Settings (Paramètres) ouverte après avoir choisi Apply (Appliquer).

6. Mappez le répertoire local à un répertoire distant pour le déploiement :

- Dans le panneau de droite de la page Deployment (Déploiement), sélectionnez l'onglet central en haut, intitulé Mappings (Mappages).
- Dans la colonne Deployment Path (Chemin d'accès du déploiement), saisissez un chemin sous /home/glue/scripts/ pour le déploiement du chemin de votre projet. olpPar exemple : /home/glue/scripts/legislators.

- Choisissez Appliquer.


L'écran Settings (Paramètres) doit désormais ressembler à ceci :




Choisissez OK pour fermer la boîte de dialogue Settings (Paramètres).

Déploiement du script sur votre point de terminaison de développement

1. Choisissez Tools (Outils), Deployment (Déploiement), puis choisissez le nom sous lequel vous configurez votre point de terminaison de développement, comme illustré dans l'image suivante :



Une fois que votre script a été déployé, le bas de l'écran doit ressembler à ce qui suit :



2. Dans la barre de menus, choisissez Tools (Outils), Deployment (Déploiement), Automatic Upload (always) [Téléchargement automatique (toujours)]. Assurez-vous qu'une coche s'affiche en regard de Automatic Upload (always) [Téléchargement automatique (toujours)].


Lorsque cette option est activée, les fichiers modifiés PyCharm sont automatiquement téléchargés sur le terminal de développement.

Configuration d'un interpréteur distant

Configurez PyCharm pour utiliser l'interpréteur Python sur le point de terminaison de développement.

1. Dans le menu File (Fichier), choisissez Settings (Paramètres).
2. Développez les législateurs du projet et choisissez Project Interpreter (Interpréteur de projet).
3. Choisissez l'icône représentant un engrenage en regard de la liste Project Interpreter (Interpréteur de projet), puis choisissez Add (Ajouter).
4. Dans la boîte de dialogue Add Python Interpreter (Ajouter un interpréteur Python) dans le panneau gauche, sélectionnez SSH Interpreter (Interpréteur SSH).
5. Choisissez Existing server configuration (Configuration du serveur existant), et, dans la liste Deployment configuration (Configuration du déploiement), choisissez votre configuration.

Votre écran doit ressembler à l'image suivante.



6. Choisissez Move this server to IDE settings (Déplacer ce serveur dans les paramètres IDE, puis choisissez Next (Suivant).
7. Dans le champ Interpreter (Interpréteur) modifiez le chemin d'accès en `/usr/bin/gluepython` si vous utilisez Python 2, ou en `/usr/bin/gluepython3` si vous utilisez Python 3. Choisissez ensuite Finish (Terminer).

Exécution de votre script sur le point de terminaison de développement

Pour exécuter le script :

- Dans le volet de gauche, cliquez avec le bouton droit sur le nom du fichier et choisissez Exécuter **<filename>** « ».

Après une série de messages, la sortie finale doit afficher le nombre et le schéma.

```
Count: 1961
root
|-- family_name: string
|-- name: string
|-- links: array
|   |-- element: struct
|       |-- note: string
|       |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|   |-- element: struct
```

```
|      |-- scheme: string
|      |-- identifier: string
|-- other_names: array
|   |-- element: struct
|       |-- lang: string
|       |-- note: string
|       |-- name: string
|-- sort_name: string
|-- images: array
|   |-- element: struct
|       |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|   |-- element: struct
|       |-- type: string
|       |-- value: string
|-- death_date: string
```

Process finished with exit code 0

Vous êtes maintenant en mesure de déboguer votre script à distance sur votre point de terminaison de développement.

Configuration avancée : partage de points de terminaison de développement entre plusieurs utilisateurs

Cette section explique comment vous pouvez tirer parti des terminaux de développement à l'aide de SageMaker blocs-notes dans des cas d'utilisation typiques pour partager des points de développement entre plusieurs utilisateurs.

Configuration à location unique

Dans les cas d'utilisation à locataire unique, pour simplifier l'expérience du développeur et éviter les conflits de ressources, il est recommandé que chaque développeur utilise son propre point de terminaison de développement dimensionné pour le projet sur lequel il travaille. Cela simplifie également les décisions liées au type de travailleur et au nombre de DPU, les laissant à la discrétion du développeur et du projet sur lequel ils travaillent.

Vous n'aurez pas besoin de vous occuper de l'allocation des ressources, sauf si vous exécutez plusieurs fichiers de bloc-notes simultanément. Si vous exécutez du code dans plusieurs fichiers de bloc-notes simultanément, plusieurs séances Livy seront lancées simultanément. Pour séparer les configurations de cluster Spark afin d'exécuter plusieurs séances Livy simultanément, vous pouvez suivre les étapes qui sont introduites dans les cas d'utilisation multi-locataire.

Par exemple, si votre point de terminaison de développement a 10 processus et que le type de processus est `G.1X`, alors vous aurez 9 programmes d'exécution Spark et l'ensemble du cluster aura 90 Go de mémoire d'exécuteur puisque chaque exécuteur aura 10 Go de mémoire.

Quel que soit le type de nœud de processus spécifié, l'allocation dynamique des ressources Spark sera activée. Si un jeu de données est suffisamment volumineux, Spark peut allouer tous les programmes d'exécution à une seule séance Livy, car `spark.dynamicAllocation.maxExecutors` n'est pas défini par défaut. Cela signifie que d'autres séances Livy sur le même point de terminaison de développement attendront le lancement de nouveaux programmes d'exécution. Si le jeu de données est peu volumineux, Spark pourra allouer des programmes d'exécution à plusieurs séances Livy en même temps.

Note

Pour plus d'informations sur la façon dont les ressources sont allouées dans différents cas d'utilisation et sur la façon dont vous définissez une configuration pour modifier le comportement, consultez [Configuration avancée : partage de points de terminaison de développement entre plusieurs utilisateurs](#).

Configuration multilocataire

Note

Veuillez noter que les points de terminaison de développement sont destinés à émuler AWS Glue Environnement ETL en tant qu'environnement à locataire unique. Bien que l'utilisation multi-locataire soit possible, il s'agit d'un cas d'utilisation avancé et il est recommandé à la plupart des utilisateurs de maintenir un modèle de locataire unique pour chaque point de terminaison de développement.

Dans les cas d'utilisation multilocataires, vous devrez peut-être vous occuper de l'allocation des ressources. Le facteur clé est le nombre d'utilisateurs qui utilisent un bloc-notes Jupyter

simultanément. Si votre équipe travaille dans un flux de travail follow-the-sun « » et qu'il n'y a qu'un seul utilisateur Jupyter par fuseau horaire, le nombre d'utilisateurs simultanés est d'un seul. Vous n'aurez donc pas à vous soucier de l'allocation des ressources. Cependant, si votre bloc-notes est partagé entre plusieurs utilisateurs et que chaque utilisateur soumet du code de manière ad hoc, vous devrez alors prendre en compte les points ci-dessous.

Pour partitionner les ressources du cluster Spark entre plusieurs utilisateurs, vous pouvez utiliser SparkMagic des configurations. Il existe deux manières différentes de configurer SparkMagic.

(A) Utiliser la directive %%configure -f

Si vous souhaitez modifier la configuration par séance Livy à partir du bloc-notes, vous pouvez exécuter la directive `%%configure -f` sur le paragraphe du bloc-notes.

Par exemple, si vous souhaitez exécuter l'application Spark sur 5 programmes d'exécution, vous pouvez exécuter la commande suivante sur le paragraphe du bloc-notes.

```
%%configure -f
{"numExecutors":5}
```

Ensuite, vous ne verrez que 5 programmes d'exécution en cours d'exécution pour le travail sur l'interface utilisateur Spark.

Nous vous recommandons de limiter le nombre maximum d'exécuteurs pour l'allocation dynamique des ressources.

```
%%configure -f
{"conf":{"spark.dynamicAllocation.maxExecutors":"5"}}
```

(B) Modifier le fichier de SparkMagic configuration

SparkMagic fonctionne sur la base de l'[API Livy](#). SparkMagic crée des sessions Livy avec des configurations telles que `driverMemory`, `driverCores`, `executorMemory`, `executorCores`, `numExecutors`, `conf`, etc. Ce sont les facteurs clés qui déterminent la quantité de ressources consommées par l'ensemble du cluster Spark. SparkMagic vous permet de fournir un fichier de configuration pour spécifier les paramètres qui sont envoyés à Livy. Pour voir un exemple de fichier de configuration, consultez ce [référéntiel Github](#).

Si vous souhaitez modifier la configuration de toutes les séances Livy à partir d'un bloc-notes, vous pouvez modifier `/home/ec2-user/.sparkmagic/config.json` pour ajouter `session_config`.

Pour modifier le fichier de configuration sur une instance de SageMaker bloc-notes, vous pouvez suivre ces étapes.

1. Ouvrez un SageMaker bloc-notes.
2. Ouvrez le noyau Terminal.
3. Exécutez les commandes suivantes :

```
sh-4.2$ cd .sparkmagic
sh-4.2$ ls
config.json logs
sh-4.2$ sudo vim config.json
```

Par exemple, vous pouvez ajouter ces lignes à `/home/ec2-user/.sparkmagic/config.json` et redémarrer le noyau Jupyter à partir du bloc-notes.

```
"session_configs": {
  "conf": {
    "spark.dynamicAllocation.maxExecutors": "5"
  }
},
```

Consignes et bonnes pratiques

Pour éviter ce type de conflit de ressources, vous pouvez utiliser des approches de base telles que :

- Accroître la taille d'un cluster Spark en augmentant `NumberOfWorkers` (mise à l'échelle horizontale) et en mettant à niveau `workerType` (mise à l'échelle verticale)
- Allouer moins de ressources par utilisateur (moins de ressources par séance Livy)

Votre approche dépendra de votre cas d'utilisation. Si vous avez un point de terminaison de développement plus important et qu'il n'y a pas une énorme quantité de données, la possibilité d'un conflit de ressources diminuera considérablement, car Spark peut allouer des ressources en fonction d'une stratégie d'allocation dynamique.

Comme décrit ci-dessus, le nombre de programmes d'exécution Spark peut être calculé automatiquement en fonction d'une combinaison de DPU (ou `NumberOfWorkers`) et de type de processus. Chaque application Spark lance un pilote et plusieurs programmes d'exécution. Pour effectuer un calcul, `NumberOfWorkers` devra être égal à `NumberOfExecutors + 1`. La

matrice ci-dessous explique la capacité dont vous avez besoin dans votre point de terminaison de développement en fonction du nombre d'utilisateurs simultanés.

Nombre d'utilisateurs simultanés de blocs-notes	Nombre d'exécuteurs Spark que vous souhaitez allouer par utilisateur	Total NumberOfWorkers pour votre point de terminaison de développement
3	5	18
10	5	60
50	5	300

Si vous souhaitez allouer moins de ressources par utilisateur, `spark.dynamicAllocation.maxExecutors` (ou `numExecutors`) serait le paramètre le plus simple à configurer en tant que paramètre de séance Livy. Si vous définissez la configuration ci-dessous/`home/ec2-user/.sparkmagic/config.json`, vous SparkMagic attribuerez un maximum de 5 exécuteurs par session Livy. Cela aidera à répartir les ressources par séance Livy.

```
"session_configs": {
  "conf": {
    "spark.dynamicAllocation.maxExecutors": "5"
  }
},
```

Supposons qu'il y ait un point de terminaison de développement avec 18 processus (G.1X) et qu'il y ait 3 utilisateurs de blocs-notes simultanément. Si votre configuration de séance dispose de `spark.dynamicAllocation.maxExecutors=5`, chaque utilisateur peut utiliser 1 pilote et 5 programmes d'exécution. Il n'y aura pas de conflits de ressources même si vous exécutez plusieurs paragraphes de bloc-notes en même temps.

Compromis

Avec cette configuration de séance `"spark.dynamicAllocation.maxExecutors": "5"`, vous pourrez éviter les erreurs de conflit de ressources et vous n'aurez pas besoin d'attendre l'allocation des ressources lorsqu'il y a des accès utilisateurs simultanés. Cependant, même lorsqu'il existe de nombreuses ressources gratuites (par exemple, il n'y a pas d'autres utilisateurs simultanés), Spark ne peut pas affecter plus de 5 programmes d'exécution pour votre séance Livy.

Autres remarques

Il est recommandé d'arrêter le noyau Jupyter lorsque vous arrêtez d'utiliser un bloc-notes. Cela libérera des ressources et les autres utilisateurs de blocs-notes pourront utiliser ces ressources immédiatement sans attendre l'expiration du noyau (arrêt automatique).

Problèmes courants

Même en suivant les directives, vous pouvez rencontrer certains problèmes.

Séance introuvable

Lorsque vous essayez d'exécuter un paragraphe de bloc-notes même si votre séance Livy est déjà résiliée, vous verrez le message ci-dessous. Pour activer la séance Livy, vous devez redémarrer le noyau Jupyter en sélectionnant Kernel (Noyau) > Restart (Redémarrer) dans le menu Jupyter, puis exécuter à nouveau le paragraphe du bloc-notes.

```
An error was encountered:  
Invalid status code '404' from http://localhost:8998/sessions/13 with error payload:  
"Session '13' not found."
```

Nombre de ressources YARN insuffisant

Lorsque vous essayez d'exécuter un paragraphe de bloc-notes même si votre cluster Spark ne dispose pas de suffisamment de ressources pour démarrer une nouvelle séance Livy, le message ci-dessous s'affiche. Vous pouvez souvent éviter ce problème en suivant les instructions. Cependant, il est possible que vous soyez confronté à ce problème. Pour contourner le problème, vous pouvez vérifier s'il existe des séances Livy actives inutiles. S'il existe des séances Livy inutiles, vous devrez les résilier pour libérer les ressources du cluster. Pour en savoir plus, consultez la section suivante.

```
Warning: The Spark session does not have enough YARN resources to start.  
The code failed because of a fatal error:  
    Session 16 did not start up in 60 seconds..
```

Some things to try:

- a) Make sure Spark has enough available resources for Jupyter to create a Spark context.
- b) Contact your Jupyter administrator to make sure the Spark magics library is configured correctly.
- c) Restart the kernel.

Surveillance et débogage

Cette section décrit les techniques de surveillance des ressources et des séances.

Surveillance et débogage de l'allocation des ressources du cluster

Vous pouvez consulter l'interface utilisateur de Spark pour contrôler le nombre de ressources allouées par séance Livy et quelles sont les configurations Spark efficaces sur la tâche. Pour activer l'interface utilisateur de Spark, consultez [Activation de l'interface utilisateur web Apache Spark pour les points de terminaison de développement](#).

(Facultatif) Si vous avez besoin d'une vue en temps réel de l'interface utilisateur Spark, vous pouvez configurer un tunnel SSH sur le serveur d'historique Spark exécuté sur le cluster Spark.

```
ssh -i <private-key.pem> -N -L 8157:<development endpoint public address>:18080  
glue@<development endpoint public address>
```

Vous pouvez alors ouvrir la page <http://localhost:8157> dans votre navigateur pour afficher localement l'interface utilisateur Spark.

Séances Livy gratuites inutiles

Passez en revue ces procédures pour arrêter toutes les séances Livy inutiles à partir d'un bloc-notes ou d'un cluster Spark.

(a). Résilier les séances Livy à partir d'un bloc-notes

Vous pouvez arrêter le noyau sur un bloc-notes Jupyter pour résilier aux séances Livy inutiles.

(b). Résilier les séances Livy à partir d'un cluster Spark

Si des séances Livy inutiles sont toujours en cours d'exécution, vous pouvez les arrêter sur le cluster Spark.

Avant d'effectuer cette procédure, vous devez configurer votre clé publique SSH pour votre point de terminaison de développement.

Pour vous connecter au cluster Spark, vous pouvez exécuter la commande suivante :

```
$ ssh -i <private-key.pem> glue@<development endpoint public address>
```

Vous pouvez exécuter la commande suivante pour voir les séances Livy actives :

```
$ yarn application -list
20/09/25 06:22:21 INFO client.RMPProxy: Connecting to ResourceManager at
ip-255-1-106-206.ec2.internal/172.38.106.206:8032
Total number of applications (application-types: [] and states: [SUBMITTED, ACCEPTED,
RUNNING]):2
Application-Id Application-Name Application-Type User Queue State Final-State Progress
Tracking-URL
application_1601003432160_0005 livy-session-4 SPARK livy default RUNNING UNDEFINED 10%
http://ip-255-1-4-130.ec2.internal:41867
application_1601003432160_0004 livy-session-3 SPARK livy default RUNNING UNDEFINED 10%
http://ip-255-1-179-185.ec2.internal:33727
```

Vous pouvez ensuite fermer la séance Livy avec la commande suivante :

```
$ yarn application -kill application_1601003432160_0005
20/09/25 06:23:38 INFO client.RMPProxy: Connecting to ResourceManager at
ip-255-1-106-206.ec2.internal/255.1.106.206:8032
Killing application application_1601003432160_0005
20/09/25 06:23:39 INFO impl.YarnClientImpl: Killed application
application_1601003432160_0005
```

Gestion des blocs-notes

Note

Les points de terminaison de développement ne sont pris en charge que pour les versions AWS Glue antérieures à 2.0. Pour un environnement interactif dans lequel vous pouvez créer et tester des scripts ETL, utilisez [Notebooks on AWS Glue Studio](#).

Un bloc-notes permet le développement et les tests interactifs de vos scripts ETL (extraction, transformation et chargement) sur un point de terminaison de développement. AWS Glue fournit une interface aux ordinateurs portables SageMaker AI Jupyter. Avec AWS Glue, vous créez et gérez des blocs-notes SageMaker dotés d'intelligence artificielle. Vous pouvez également ouvrir des blocs-notes SageMaker AI à partir du AWS Glue console.

En outre, vous pouvez utiliser Apache Spark avec SageMaker AI sur AWS Glue terminaux de développement qui prennent en charge l' SageMaker IA (mais pas AWS Glue Emplois ETL).

SageMaker Spark est une bibliothèque Apache Spark open source pour l' SageMaker IA. Pour plus d'informations, consultez la section [Utilisation d'Apache Spark avec Amazon SageMaker](#).

 Important

Gestion des blocs-notes SageMaker dotés d'intelligence artificielle avec AWS Glue
les points de terminaison de développement sont disponibles dans les AWS régions suivantes :

Région	Code
USA Est (Ohio)	us-east-2
USA Est (Virginie du Nord)	us-east-1
USA Ouest (Californie du Nord)	us-west-1
USA Ouest (Oregon)	us-west-2
Asie Pacifique (Tokyo)	ap-northeast-1
Asie-Pacifique (Séoul)	ap-northeast-2
Asie-Pacifique (Mumbai)	ap-south-1
Asie-Pacifique (Singapour)	ap-southeast-1
Asie-Pacifique (Sydney)	ap-southeast-2
Canada (Centre)	ca-central-1
Europe (Francfort)	eu-central-1
Europe (Irlande)	eu-west-1
Europe (Londres)	eu-west-2

Création de tâches ETL visuelles avec AWS Glue Studio

Un AWS Glue job encapsule un script qui se connecte à vos données source, les traite, puis les écrit dans votre cible de données. En général, une tâche exécute les scripts d'extraction, de transformation et de chargement (ETL). Les tâches peuvent exécuter des scripts conçus pour les environnements d'exécution Apache Spark et Ray. Les tâches peuvent également exécuter des scripts Python à usage général (tâches Python shell). AWS Glue les déclencheurs peuvent démarrer des tâches en fonction d'un calendrier, d'un événement ou à la demande. Vous pouvez surveiller les exécutions de tâche pour comprendre les métriques d'exécution telles que le statut d'achèvement, la durée et l'heure de début.

Vous pouvez utiliser des scripts que AWS Glue génère ou vous pouvez fournir le vôtre. Avec un schéma source et un emplacement ou un schéma cible, le AWS Glue Studio Le générateur de code peut créer automatiquement un script Apache Spark API (PySpark). Vous pouvez utiliser ce script comme point de départ et le modifier en fonction de vos objectifs.

AWS Glue peut écrire des fichiers de sortie dans plusieurs formats de données. Chaque type de tâche peut prendre en charge différents formats de sortie. Pour certains formats de données, des formats de compression courants peuvent être écrits.

En vous connectant au AWS Glue console

Une tâche AWS Glue comprend la logique métier qui exécute les tâches d'extraction, de transformation et de chargement (ETL). Vous pouvez créer des tâches dans la section ETL du AWS Glue console.

Pour consulter les offres d'emploi existantes, connectez-vous au AWS Management Console et ouvrez le AWS Glue console à <https://console.aws.amazon.com/glue/>. Choisissez ensuite l'onglet Tâches dans AWS Glue. La liste des tâches affiche l'emplacement du script associé à chaque tâche, la date de dernière modification de la tâche et l'option de signet de la tâche en cours.

Lors de la création d'une nouvelle tâche, ou après l'avoir enregistrée, vous pouvez utiliser can AWS Glue Studio pour modifier vos tâches ETL. Vous pouvez le faire en éditant les nœuds dans l'éditeur visuel ou en modifiant le script de la tâche en mode développeur. Vous pouvez également ajouter et supprimer des nœuds dans l'éditeur visuel pour créer des tâches ETL plus compliquées.

Prochaines étapes pour créer un emploi dans AWS Glue Studio

Vous utilisez l'éditeur de tâches visuelles pour configurer les nœuds de votre tâche. Chaque nœud représente une action, telle que la lecture de données à partir de l'emplacement source ou l'application d'une transformation aux données. Chaque nœud que vous ajoutez à votre tâche possède des propriétés qui fournissent des informations sur l'emplacement des données ou la transformation.

Voici les étapes suivantes pour créer et gérer vos tâches :

- [Démarrage de tâches Visual ETL dans AWS Glue Studio](#)
- [Afficher le script de tâche](#)
- [Modifier les propriétés de tâche](#)
- [Sauvegarder la tâche](#)
- [Démarrer une exécution de tâche](#)
- [Afficher les informations sur les exécutions de tâche récentes](#)
- [Accès au tableau de bord de surveillance de tâche](#)

Démarrage de tâches Visual ETL dans AWS Glue Studio

Vous pouvez utiliser l'interface visuelle simple dans AWS Glue Studio pour créer vos tâches ETL. Vous utilisez la page Tâches pour créer des tâches. Vous pouvez également utiliser un éditeur de script ou un bloc-notes pour travailler directement avec le code du AWS Glue Studio Script de tâche ETL.

Sur la page Offres d'emploi, vous pouvez voir toutes les tâches que vous avez créées soit avec AWS Glue Studio or AWS Glue. Vous pouvez consulter, gérer et exécuter vos tâches sur cette page.

Voir également le [tutoriel du blog](#) sur un autre exemple de création de tâches ETL avec AWS Glue Studio.


Création d'un emploi dans AWS Glue Studio

AWS Glue vous permet de créer une tâche par le biais d'une interface visuelle, d'un bloc-notes de code interactif ou d'un éditeur de script. Vous pouvez démarrer une tâche en cliquant sur l'une des options ou créer une nouvelle tâche à partir d'un exemple de tâche.

Les exemples de tâches créent une tâche à l'aide de l'outil de votre choix. Par exemple, les exemples de tâches vous permettent de créer une tâche ETL visuelle qui joint des fichiers CSV dans une table de catalogue, de créer une tâche dans un bloc-notes de code interactif avec AWS Glue pour Ray ou AWS Glue pour Spark lorsque vous travaillez avec des pandas, ou créez une tâche dans un bloc-notes de code interactif avec SparkSQL.

Création d'un emploi dans AWS Glue Studio à partir de zéro

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue Studio console à <https://console.aws.amazon.com/gluestudio/>.
2. Dans le panneau de navigation, choisissez Tâches ETL.
3. Dans la section Créer une tâche, sélectionnez une option de configuration pour votre tâche.



Options pour créer une tâche à partir de zéro :

- ETL visuelle : créez une interface visuelle axée sur le flux de données
- Créer à l'aide d'un bloc-notes de code interactif : créez des tâches de manière interactive dans une interface de bloc-notes basée sur les blocs-notes Jupyter.

Lorsque vous sélectionnez cette option, vous devez fournir des informations supplémentaires avant de créer une session de création de blocs-notes. Pour plus d'informations sur la manière de spécifier ces informations, veuillez consulter [Commencer à utiliser les blocs-notes dans AWS Glue Studio](#).

- Créer du code avec un éditeur de script : pour ceux qui connaissent la programmation et l'écriture de scripts ETL, vous pouvez choisir cette option pour créer une nouvelle tâche ETL Spark. Choisissez le moteur (shell Python, Ray, Spark [Python] ou Spark [Scala]). Choisissez ensuite Redémarrer ou Charger un script pour charger un script existant à partir d'un fichier

local. Si vous choisissez d'utiliser l'éditeur de script, vous ne pouvez pas utiliser l'éditeur de tâches visuel.

Une tâche Spark est exécutée dans un environnement Apache Spark géré par AWS Glue. Par défaut, les nouveaux scripts sont codés en Python. Pour écrire un nouveau script Scala, veuillez consulter [Création et modification de scripts Scala dans AWS Glue Studio](#).

Création d'un emploi dans AWS Glue Studio à partir d'un exemple de tâche

Vous pouvez choisir de créer une tâche à partir d'un exemple de tâche. Dans la section Exemples de tâches, choisissez un exemple de tâche, puis choisissez Créer un exemple de tâche. La création d'un exemple de tâche à partir de l'une des options fournit un modèle rapide à partir duquel vous pouvez travailler.

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue Studio console à <https://console.aws.amazon.com/gluestudio/>.
2. Dans le panneau de navigation, choisissez Tâches ETL.
3. Sélectionnez une option pour créer une tâche à partir d'un exemple de tâche :
 - Tâche ETL visuelle pour de joindre plusieurs sources : lisez trois fichiers CSV, combinez les données, modifiez les types de données, puis écrivez les données dans Amazon S3 et cataloguez-les pour les interroger ultérieurement.
 - Bloc-notes Spark utilisant Pandas : explorez et visualisez les données à l'aide du célèbre cadre Pandas combiné à Spark.
 - Bloc-notes Spark utilisant SQL : utilisez SQL pour démarrer rapidement avec Apache Spark. Accédez aux données par le biais du AWS Glue Cataloguez les données et transformez-les à l'aide de commandes familières.
4. Choisissez Créer un exemple de tâche.

Fonctionnalités de l'éditeur de tâche

L'éditeur de tâches fournit les fonctionnalités suivantes pour la création et la modification des tâches.

- Un diagramme visuel de votre tâche, avec un nœud pour chaque tâche : nœuds de source de données pour la lecture des données ; nœuds de transformation pour la modification des données ; nœuds de données cibles pour l'écriture des données.

Vous pouvez afficher et configurer les propriétés de chaque nœud dans le diagramme de tâches. Vous pouvez également afficher le schéma et les échantillons de données pour chaque nœud dans le diagramme de tâche. Ces fonctionnalités vous aident à vérifier que votre tâche modifie et transforme les données de la bonne manière, sans avoir à exécuter la tâche.

- Un onglet d'affichage et d'édition de script, dans lequel vous pouvez modifier le code généré pour votre tâche.
- Un onglet Détails du Job, dans lequel vous pouvez configurer divers paramètres pour personnaliser l'environnement dans lequel votre AWS Glue La tâche ETL s'exécute.
- Un onglet Exécutions, dans lequel vous pouvez afficher les exécutions actuelles et précédentes de la tâche, afficher l'état de l'exécution de celle-ci et accéder à ses journaux d'exécution.
- Un onglet Qualité des données, dans lequel vous pouvez appliquer des règles de qualité des données à votre tâche.
- Un onglet Planifications, dans lequel vous pouvez configurer l'heure de début de votre tâche ou configurer une exécution de tâche récurrente.
- Un onglet Contrôle de version, dans lequel vous pouvez configurer un service Git à utiliser avec votre tâche.

Utilisation des prévisualisations de schéma dans l'éditeur de tâches visuel

Lorsque vous créez ou modifiez votre tâche, vous pouvez utiliser l'onglet Output Schema (Schéma de sortie) pour afficher le schéma de vos données.

Avant de voir le schéma, l'éditeur de tâche a besoin d'autorisations pour accéder à la source de données. Vous pouvez spécifier un rôle IAM dans l'onglet Détails de la tâche de l'éditeur ou dans l'onglet Output Schema (Schéma de sortie) pour chaque nœud. Si le rôle IAM dispose de toutes les autorisations nécessaires pour accéder à la source de données, vous pouvez alors afficher le schéma dans l'onglet Schema pour chaque nœud.

Utilisation des prévisualisations de données dans l'éditeur de tâches visuel

Les prévisualisations des données vous aident à créer et à tester votre tâche à l'aide d'un échantillon de vos données, sans avoir à exécuter la tâche de manière répétée. En utilisant la prévisualisation des données, vous pouvez :

- Tester un rôle IAM pour vous assurer que vous avez accès à vos sources de données ou cibles de données.
- Vérifier que la transformation modifie les données de la manière prévue. Par exemple, si vous utilisez une transformation de filtre, vous pouvez vous assurer que le filtre sélectionne le sous-ensemble de données approprié.
- Vérifiez vos données. Si votre jeu de données contient des colonnes avec des valeurs de plusieurs types, l'aperçu des données affiche une liste de tuples pour ces colonnes. Chaque tuple contient le type de données et sa valeur.

Note

Si vous utilisez une session d'aperçu des données et un code SQL personnalisé ou un nœud de code personnalisé, la session d'aperçu des données exécutera le code SQL ou le bloc de code tel quel pour l'ensemble de données.

Lors de la création ou de la modification de votre tâche, vous pouvez utiliser l'onglet Prévisualisation des données sous le canevas de la tâche pour afficher un échantillon de vos données. Une nouvelle session de prévisualisation des données démarre automatiquement lorsque le rôle est déjà configuré dans la tâche ou qu'un rôle IAM par défaut a été configuré dans le compte. Si aucun rôle n'a été configuré auparavant, vous pouvez démarrer une session en sélectionnant le rôle.

Data preview

Output schema



Start a data preview session

IAM role

To start a data preview session, choose an IAM role for this job. Changing the role will end an existing data preview session.

Admin

No description available.

▼

[Create IAM role.](#) 

► **Additional Settings**


Start session

Note

Le rôle que vous choisissez pour la session de prévisualisation des données sera également utilisé pour la tâche.

Vous pouvez voir l'état et la progression de votre session ainsi que les détails de la session en cliquant sur l'icône d'information.

Lorsque la session est prête, AWS Glue Studio chargera les données du nœud que vous avez sélectionné. Vous pouvez voir le % d'avancement au fur et à mesure de sa progression.



Lorsque vous rédigez votre travail visuel, AWS Glue Studio mettra automatiquement à jour le schéma du nœud sélectionné lorsque vous désactiverez le schéma Infer de la session dans l'onglet Schéma de sortie.

The screenshot displays the AWS Glue console interface for configuring a 'Transform - SQL Query' node. The node is highlighted with a blue border and a green checkmark. The 'Output schema' tab is active, showing a table with columns: Key, Data type, firstname (string), lastname (string), title (string). The 'SQL query' tab shows a query: 'select firstname, lastname, title from myDataSource'. The 'Input sources' section shows 'Amazon S3' and 'myDataSource'.

Pour configurer vos préférences pour les prévisualisations des données :

Choisissez l'icône des paramètres (symbole d'engrenage) pour configurer vos préférences pour les prévisualisations des données. Ces paramètres s'appliquent à tous les nœuds dans le diagramme de tâche. Vous pouvez :

- Choisir d'envelopper le texte d'une ligne à l'autre. Cette option est activée par défaut
- Modifier le nombre de lignes (200 par défaut)
- Choisir un rôle IAM ou en créer un si nécessaire
- Choisir de démarrer automatiquement une nouvelle session lorsque vous créez une tâche. Cela permet d'ouvrir une nouvelle session interactive lors de la création de tâches. Ce paramètre s'applique au niveau du compte. Une fois défini, il s'appliquera à tous les utilisateurs de votre compte lors de la modification d'une tâche.
- Choisir de déduire automatiquement le schéma. Les schémas en sortie seront automatiquement déduits pour le nœud sélectionné
- Choisissez d'importer automatiquement AWS Glue bibliothèques. Ceci est utile pour empêcher la prévisualisation des données de redémarrer de nouvelles sessions lors de l'ajout de nouvelles transformations nécessitant un redémarrage de session

Preferences

☒ **Wrap lines**
Enable to wrap lines of table cell content, disable to truncate text.

Number of rows
Enter the amount of entries to sample from the dataset.

IAM role
To start a data preview session, choose an IAM role for this job. Changing the role will end an existing data preview session.

Admin

No description available.

▼

[Create IAM role.](#)

☐ **Automatically start data preview sessions**
Data preview will automatically start new interactive sessions when entering the visual job editor enabling you to preview data more efficiently.
⚠ This setting applies to all users in your account.

☒ **Infer schema from session**
Output schemas will be automatically inferred based on the result of the datapreview execution

☒ **Automatically import glue libraries**
Some ETL transform require extra libraries to be imported in the datapreview session, enabling this option will automatically import them to your sessions in order to prevent session from restarting during your job authoring. Note: the IAM role require read permission to Glue S3 bucket to prevent failures.

Cancel

Confirm

Les fonctionnalités supplémentaires incluent la possibilité de :

- Choisissez le bouton **Previewing x of y fields** (Prévisualiser x des y champs) pour sélectionner les colonnes (champs) à afficher. Lorsque vous prévisualisez vos données à l'aide des paramètres par

défaut, l'éditeur de tâches affiche les 5 premières colonnes de votre jeu de données. Vous pouvez le modifier pour afficher tout ou aucun (non recommandé).

- Faire défiler la fenêtre de prévisualisation des données horizontalement et verticalement.
- Utilisez le bouton d'agrandissement pour étendre l'onglet Prévisualisation des données et le superposer au graphique des tâches afin de mieux visualiser les données et les structures de données. De même, utilisez le bouton de réduction pour réduire l'onglet Prévisualisation des données. Vous pouvez également saisir le panneau de poignée et le faire glisser vers le haut pour développer l'onglet Prévisualisation des données.

The screenshot shows the AWS Glue console interface. At the top, there are tabs: Visual, Script, Job details, Runs, Data quality New, Schedules, and Version Control. The Visual tab is active, displaying a data pipeline diagram. A data source box labeled 'Data source - S3 bucket Amazon S3' with a green checkmark is connected to a data target box labeled 'Data target - Snowflake'. Below the diagram, there is a 'Data preview' section. It has two tabs: 'Data preview' (selected) and 'Output schema'. The 'Data preview' tab shows a table with 5 columns: venueid, venue name, venue city, venue state, and venue seats. The table contains 3 rows of data. A search bar labeled 'Filter sample dataset' is above the table. To the right of the table, there are buttons for 'End session' and 'Previewing 5 of 5 fields'. A red rectangle highlights the 'Data preview' tab and the 'End session' button.

venueid	venue name	venue city	venue state	venue seats
1	Toyota Park	Bridgeview	IL	0
2	Columbus Crew Stadium	Columbus	OH	0
3	RFK Stadium	Washington	DC	0

- Cliquez sur Mettre fin à la session pour arrêter la prévisualisation des données. Lorsque vous arrêtez la session, vous pouvez choisir un nouveau rôle IAM et définir des paramètres supplémentaires (tels que les paramètres d'activation ou de désactivation) pour démarrer automatiquement une nouvelle session, déduire un schéma ou importer AWS Glue bibliothèques, et redémarrez la session.

Restrictions lors de l'utilisation de prévisualisations de données

Lorsque vous utilisez des prévisualisations de données, il se peut que vous disposiez des restrictions ou limitations suivantes.

- La première fois que vous choisissez l'onglet Data preview (Prévisualisation des données), vous devez choisir le rôle IAM. Ce rôle doit disposer des autorisations nécessaires pour accéder aux données et aux autres ressources nécessaires à la création des prévisualisations de données.
- Une fois que vous avez fourni un rôle IAM, il faut un certain temps avant que les données soient disponibles pour l'affichage. Pour les jeux de données avec moins de 1 Go de données, cela peut prendre jusqu'à une minute. Si vous disposez d'un jeu de données volumineux, vous devriez utiliser des partitions pour améliorer le temps de chargement. Le chargement des données directement à partir d'Amazon S3 offre les meilleures performances.
- Si vous disposez d'un jeu de données très volumineux et qu'il faut plus de 15 minutes pour interroger les données pour la prévisualisation des données, la requête expire. Les aperçus des données ont un délai d'inactivité de 30 minutes. Pour pallier ce problème, réduisez la taille du jeu de données pour utiliser des prévisualisations de données.
- Par défaut, les 50 premières colonnes s'affichent dans l'onglet Prévisualisation des données. Si les colonnes n'ont pas de valeurs de données, vous recevrez un message indiquant qu'il n'y a pas de données à afficher. Vous pouvez augmenter le nombre de lignes échantillonnées ou sélectionner différentes colonnes pour afficher les valeurs de données.
- Les prévisualisations de données ne sont actuellement pas prises en charge pour les sources de données en streaming ou pour les sources de données qui utilisent des connecteurs personnalisés.
- Les erreurs sur un nœud affectent l'ensemble de la tâche. Si un nœud a une erreur avec les prévisualisations de données, l'erreur apparaîtra sur tous les nœuds jusqu'à ce que vous le corrigiez.
- Si vous modifiez une source de données pour la tâche, il se peut que les nœuds enfants de cette source de données doivent être mis à jour pour correspondre au nouveau schéma. Par exemple, si un ApplyMapping nœud modifie une colonne et que celle-ci n'existe pas dans la source de données de remplacement, vous devez mettre à jour le nœud de ApplyMapping transformation.
- Si vous affichez l'onglet Prévisualisation des données pour un nœud de transformation de requête SQL et que la requête SQL utilise un nom de champ incorrect, l'onglet Prévisualisation des données affiche une erreur.

Génération de code de script

Lorsque vous utilisez l'éditeur visuel pour créer une tâche, le code ETL est automatiquement généré pour vous. AWS Glue Studio crée un script de tâche fonctionnel et complet, et l'enregistre dans un emplacement Amazon S3.

Il existe deux formes de code généré par AWS Glue Studio: la version originale, ou version classique, et une version plus récente et simplifiée. Par défaut, le nouveau générateur de code est utilisé pour créer le script de tâche. Vous pouvez générer un script de tâche à l'aide du générateur de code classique dans l'onglet Script en sélectionnant le bouton à bascule Generate classic script (Générer un script classique).

Voici quelques-unes des différences de la nouvelle version du code généré :

- Les blocs de commentaires volumineux ne sont plus ajoutés au script
- Les structures de sortie du code utilisent le nom du nœud que vous spécifiez dans l'éditeur visuel. Dans le script de classe, les structures de sortie sont simplement nommées DataSource0, DataSource1, Transform0, Transform1, DataSink0, DataSink1, etc.
- Les commandes longues sont réparties sur plusieurs lignes pour supprimer le besoin de faire défiler la page pour voir l'ensemble de la commande.

Nouvelles fonctionnalités dans AWS Glue Studio nécessitent la nouvelle version de génération de code et ne fonctionneront pas avec le script de code classique. Il vous est proposé de mettre à jour ces tâches lorsque vous tentez de les exécuter.

Transformez les données avec AWS Glue transformations gérées

AWS Glue Studio propose deux types de transformations :

- AWS Glue-transformations natives - disponibles pour tous les utilisateurs et gérées par AWS Glue.
- Transformations visuelles personnalisées : vous permet de télécharger vos propres transformations à utiliser dans AWS Glue Studio

AWS Glue nœuds de transformation de données gérés

AWS Glue Studio fournit un ensemble de transformations intégrées que vous pouvez utiliser pour traiter vos données. Vos données passent d'un nœud dans le diagramme de tâches à un autre, dans

une structure de données appelée `DynamicFrame`, qui est une extension d'un `DataFrame` SQL Apache Spark.

Dans le diagramme prérempli d'une tâche, entre la source de données et les nœuds de données cibles, se trouve le nœud de transformation Modifier le schéma. Vous pouvez configurer ce nœud de transformation pour modifier vos données ou utiliser des transformations supplémentaires.

Les transformations intégrées suivantes sont disponibles avec AWS Glue Studio:

- [ChangeSchema](#): Mappez les clés de propriété des données de la source de données aux clés de propriété des données de la cible de données. Vous pouvez renommer les clés, modifier leur type de données et choisir les clés à supprimer du jeu de données.
- [SelectFields](#): Choisissez les clés de propriété des données que vous souhaitez conserver.
- [DropFields](#): Choisissez les clés de propriété des données que vous souhaitez supprimer.
- [RenameField](#): renommez une seule clé de propriété de données.
- [Spigot](#) : écrivez des échantillons de données dans un compartiment Amazon S3.
- [Join](#) : joignez deux jeux de données dans un jeu de données à l'aide d'une phrase de comparaison sur les clés de propriété de données spécifiées. Vous pouvez utiliser des jointures internes (ou intérieures), externes (ou extérieures), gauche, droite, semi gauche et anti gauche.
- [Union](#) : combinez les lignes de plusieurs sources de données ayant le même schéma.
- [SplitFields](#): Divisez les clés de propriété des données en deux `DynamicFrames`. Le résultat est une collection de `DynamicFrames` : une avec les clés de propriété de données sélectionnées, et une autre avec les clés de propriété de données restantes.
- [SelectFromCollection](#): Choisissez-en un `DynamicFrame` parmi une collection de `DynamicFrames`. Le résultat est le `DynamicFrame` sélectionné.
- [FillMissingValues](#): Localisez les enregistrements de l'ensemble de données qui contiennent des valeurs manquantes et ajoutez un nouveau champ avec une valeur suggérée déterminée par imputation
- [Filter](#) : divisez un jeu de données en deux, en fonction d'une condition de filtrage.
- [Drop Null Fields](#) : supprime les colonnes du jeu de données si toutes les valeurs de la colonne sont « null ».
- [Drop Duplicates](#) : supprime des lignes de votre source de données en choisissant de faire correspondre des lignes entières ou de spécifier des clés.
- [SQL](#) : entrez le code SparkSQL dans un champ de saisie de texte pour utiliser une requête SQL pour transformer les données. Le résultat est un `DynamicFrame` unique .

- [Regrouper](#) : effectue un calcul (tel que la moyenne, la somme, le minimum, le maximum) sur les champs et les lignes sélectionnés, et crée un nouveau champ avec la ou les valeurs nouvellement calculées.
- [Aplatir](#) : extrait les champs des structs dans les champs de niveau supérieur.
- [UUID](#) : ajoute une colonne avec un identifiant unique universel pour chaque ligne.
- [Identifiant](#) : ajoute une colonne avec un identifiant numérique pour chaque ligne.
- [En horodatage](#) : convertit une colonne en type horodatage.
- [Formater l'horodatage](#) : convertit une colonne d'horodatage en chaîne formatée.
- [Transformation du routeur conditionnel](#) : applique plusieurs conditions aux données entrantes. Chaque ligne des données entrantes est évaluée par une condition de filtre de groupe et traitée dans le groupe correspondant.
- [Transformation Concaténer des colonnes](#) : créez une colonne de chaîne en utilisant les valeurs d'autres colonnes avec un espacement facultatif.
- [Transformation Diviser la chaîne](#) : divisez une chaîne en un tableau de jetons à l'aide d'une expression régulière pour définir la manière dont la division est effectuée.
- [Transformation Tableau vers colonnes](#) : extrayez certains ou tous les éléments d'une colonne de type tableau dans de nouvelles colonnes.
- [Transformation Ajouter un horodatage actuel](#) : marquez les lignes avec l'heure à laquelle les données ont été traitées. Ceci est utile à des fins d'audit ou pour suivre la latence dans le pipeline de données.
- [Transformation Faire pivoter les lignes en colonnes](#) : agrégez une colonne numérique en faisant pivoter des valeurs uniques sur des colonnes sélectionnées qui deviennent de nouvelles colonnes. Si plusieurs colonnes sont sélectionnées, les valeurs sont concaténées pour nommer les nouvelles colonnes.
- [Transformation Dépivoter les colonnes en lignes](#) : convertissez des colonnes en valeurs de nouvelles colonnes en générant une ligne pour chaque valeur unique.
- [Transformation Traitement de l'équilibre automatique](#) : redistribuez mieux les données entre les travailleurs. Cela est utile dans les cas où les données sont déséquilibrées ou lorsque la source ne permet pas un traitement parallèle suffisant.
- [Transformation Colonnes dérivées](#) : définissez une nouvelle colonne basée sur une formule mathématique ou une expression SQL dans laquelle vous pouvez utiliser d'autres colonnes dans les données, ainsi que des constantes et des littéraux.

- [Transformation Rechercher](#) : ajoutez des colonnes à partir d'une table de catalogue définie lorsque les clés correspondent aux colonnes de recherche définies dans les données.
- [Transformation Éclater le tableau ou la carte en lignes](#) : extrayez les valeurs d'une structure imbriquée en lignes individuelles plus faciles à manipuler.
- [Transformation Correspondance d'enregistrements](#) : invoquez une transformation de classification de données de machine learning Correspondance des enregistrements existante.
- [Transformation Supprimer les lignes nulles](#) : supprimez du jeu de données les lignes dont toutes les colonnes sont nulles ou vides.
- [Transformation Analyser la colonne JSON](#) : analysez une colonne de chaîne contenant des données JSON et convertissez-la en une structure ou en une colonne de tableau, selon que le JSON est respectivement un objet ou un tableau.
- [Transformation Extraire le chemin JSON](#) : extrayez les nouvelles colonnes d'une colonne de chaîne JSON.
- [Extraire des fragments de chaînes d'une expression régulière](#) : extrayez des fragments de chaîne à l'aide d'une expression régulière et créez une colonne à partir de celle-ci, ou plusieurs colonnes si vous utilisez des groupes d'expressions régulières.
- [Custom transform](#) : saisissez du code dans un champ de saisie de texte pour utiliser des transformations personnalisées. Le résultat est une collection de `DynamicFrames`.

Utilisation d'une recette de préparation des données dans AWS Glue Studio

La transformation des recettes de préparation des données vous permet de créer une recette de préparation des données à partir de zéro à l'aide d'une interface de création interactive de type grille. Il vous permet également d'importer une AWS Glue DataBrew recette existante, puis de la modifier AWS Glue Studio.

Le nœud Recette de préparation des données est disponible dans le panneau Ressources. Vous pouvez connecter le nœud Recette de préparation des données à un autre nœud du flux de travail visuel, qu'il s'agisse d'un nœud de source de données ou d'un autre nœud de transformation. Après avoir choisi une AWS Glue DataBrew recette et une version, les étapes appliquées dans la recette sont visibles dans l'onglet des propriétés du nœud.

Prérequis

- Si vous importez une AWS Glue DataBrew recette, vous disposez des autorisations IAM requises, comme décrit dans [Importer une AWS Glue DataBrew recette dans AWS Glue Studio](#).

- Une session de prévisualisation des données doit être créée.

Limites

- AWS Glue DataBrew les recettes ne sont prises en charge que dans [DataBrew les régions commerciales](#).
- Toutes les AWS Glue DataBrew recettes ne sont pas prises en charge par AWS Glue. Certaines recettes ne pourront pas être exécutées dans . AWS Glue Studio.
 - Les recettes avec UNION et JOIN transformations ne sont pas prises en charge, cependant, AWS Glue Studio possède déjà des nœuds de transformation « Join » et « Union » qui peuvent être utilisés avant ou après un nœud Data Preparation Recipe.
- Les nœuds Data Preparation Recipe sont pris en charge pour les tâches commençant par AWS Glue version 4.0. Cette version sera sélectionnée automatiquement après l'ajout d'un nœud Recette de préparation des données à la tâche.
- Les nœuds Recette de préparation des données nécessitent Python. Ceci est automatiquement défini lorsque le nœud Recette de préparation des données est ajouté à la tâche.
- L'ajout d'un nouveau nœud de recette de préparation des données au graphique visuel redémarrera automatiquement votre session d'aperçu des données avec les bibliothèques appropriées pour utiliser le nœud de recette de préparation des données.
- Les transformations suivantes ne sont pas prises en charge pour l'importation ou la modification dans un nœud Data Preparation Recipe : GROUP_BY PIVOTUNPIVOT,, etTRANSPOSE.


Fonctionnalités supplémentaires

Lorsque vous avez sélectionné la transformation de recette de préparation des données, vous pouvez effectuer des actions supplémentaires après avoir sélectionné la recette Author.

- Ajouter une étape : vous pouvez ajouter des étapes supplémentaires à une recette selon vos besoins en cliquant sur l'icône d'ajout d'étape, ou utiliser la barre d'outils du volet d'aperçu en choisissant une action.



- Importer une recette : choisissez Plus puis Importer une recette à utiliser dans le cadre de votre AWS Glue Studio travail.




- Télécharger au format YAML : choisissez Plus puis Télécharger au format YAML pour télécharger votre recette et l'enregistrer en dehors de. AWS Glue Studio
- Télécharger au format JSON : choisissez Plus puis Télécharger au format JSON pour télécharger votre recette à enregistrer en dehors de AWS Glue Studio.
- Annuler et rétablir les étapes de la recette : vous pouvez annuler et rétablir les étapes de la recette dans le volet d'aperçu lorsque vous travaillez avec des données dans la grille.



Créez et exécutez des recettes de préparation de données dans une AWS Glue tâche ETL visuelle

Dans ce scénario, vous pouvez créer des recettes de préparation des données sans avoir à les créer au préalable DataBrew. Avant de commencer à créer des recettes, vous devez :

- Avoir une session d'aperçu des données active en cours d'exécution. Lorsque la session de prévisualisation des données est PRÊTE, Author Recipe devient active et vous pouvez commencer à créer ou à modifier votre recette.




- Assurez-vous que l'option Importer automatiquement les bibliothèques de colle est activée.

Automatically import glue libraries

Some ETL transform require extra libraries to be imported in the datapreview session, enabling this option will automatically import them to your sessions in order to prevent session from restarting during your job authoring. Note: the IAM role require read permission to Glue S3 bucket to prevent failures.

Vous pouvez le faire en choisissant l'icône en forme de roue dentée dans le volet d'aperçu des données.



Data preview | Output schema

Data preview (200) Info **READY** ⓘ

Filter sample dataset

msisdn | plan_id

0EE9CF575F6DFC439912 83EBEFDE9DBF	422426142648
E2F7FFF946A31AB8C67B 8D0C7B74D0D1	968763331038
0C59DE5F33D3F591DD5	

Pour créer une recette de préparation des données dans AWS Glue Studio :

1. Ajoutez la transformation Data Preparation Recipe à votre canevas de travail. Votre transformation doit être connectée à un nœud de source de données parent. Lorsque vous ajoutez le nœud Data Preparation Recipe, celui-ci redémarrera avec les bibliothèques appropriées et vous verrez le bloc de données en cours de préparation.

The screenshot displays the AWS Glue Studio interface. At the top, there's a header with 'Untitled job' and a warning 'Job has not been saved'. Below the header is a toolbar with various data processing tools like Filter, Sort, Column, Format, Clean, Extract, Missing, Invalid, Duplicates, Outliers, Split, Merge, Create, Functions, Conditions, and Nest-Unnest. The main workspace shows a 'Preparing dataframe' screen with a message: 'Your session will be ready soon! Preparing dataframe. Your session will take about a minute to be ready. Once ready there will be no additional load time.' On the right, the 'Transform' sidebar is visible, showing 'Authoring Data Preparation Recipe' and 'Recipe (0)' with an 'Add step' button.

2. Une fois que la session d'aperçu des données est prête, les données contenant les étapes précédemment appliquées apparaîtront en bas de l'écran.
3. Choisissez Author Recipe. Cela vous permettra de démarrer une nouvelle recette dans AWS Glue Studio.

Transform

 **Author Data Preparation Recipe**

Author Recipe

Name

Node parents
Choose which nodes will provide inputs for this one.

Join

Join - Transform

4. Dans le panneau Transformation situé à droite du canevas de tâches, entrez le nom de votre recette de préparation des données.
5. Sur le côté gauche, le canevas sera remplacé par une vue en grille de vos données. Sur la droite, le panneau Transform changera pour vous montrer les étapes de votre recette. Choisissez Ajouter une étape pour ajouter la première étape à votre recette.

The screenshot shows the AWS Glue console in 'visual-mode'. The top navigation bar includes the AWS logo, a 'Services' menu, a search bar, and user information (N. Virginia, MyRole/AWSUser @ 0123-4567-8901). The main interface is split into two panes. The left pane, titled 'visual-mode', shows a data preview with 23 columns and 259 rows. It includes a toolbar with various actions like 'Filter', 'Sort', 'Columns', 'Format', 'Clean', 'Extract', 'Missing', 'Reveal', 'Duplicate', 'Outliers', 'Split', 'Merge', 'Create', 'Functions', 'Conditions', and 'More'. The data preview shows columns for 'id', 'name', 'age_created_at', and 'creation_date'. The right pane, titled 'Transform', shows a 'Recipe' section with a 'Done Authoring Recipe' button and a 'Data Cleanup Recipe' button. Below this, there is a 'Build your recipe' section with a diagram showing a flow from 'Data' to 'Recipe' and a text box stating 'Start applying transformation steps to your data. All your data preparation steps will be tracked in the recipe.' and an 'Add step' button.

- Dans le panneau Transformation, choisissez de trier, d'effectuer une action sur la colonne et de filtrer les valeurs. Par exemple, choisissez Renommer la colonne.

The screenshot shows the AWS Glue console in visual mode. The left pane displays a data preview with columns like 'id', 'name', 'email', 'phone', 'address', and 'creation_date'. The right pane shows the 'Transform' section with a 'Recipe' tab and a 'Done Authoring Recipe' button. Below the button are options to 'Add step', 'Find steps', 'SORT' (Ascending, Descending), 'COLUMN ACTIONS' (Rename, Change type, Move column, Duplicate, Delete), and 'FILTER' (Missing values, Invalid values, By condition).

7. Dans le panneau Transformation sur le côté droit, les options permettant de renommer une colonne vous permettent de choisir la colonne source à renommer et de saisir le nouveau nom de colonne. Une fois que vous l'avez fait, choisissez Appliquer.

Vous pouvez prévisualiser chaque étape, annuler une étape, réorganiser les étapes et utiliser n'importe laquelle des icônes d'action, telles que Filtrer, Trier, Diviser, Fusionner, etc. Lorsque vous effectuez des actions dans la grille de données, les étapes sont ajoutées à la recette dans le panneau Transformation.

The screenshot displays the AWS Glue Studio interface. On the left, the 'Preview' pane shows a table with columns: `id`, `name`, `rating`, `created_at`, and `creation_date`. The table contains 259 rows. On the right, the 'Transform' pane shows a 'Recipe' titled 'Data Cleanup Recipe'. The recipe steps are:

1. Change type of column `name` to `Boolean`
2. Delete column `extra_data`
3. Create duplicate column `copy_of_last_name` from `last_name`
4. Change type of address to `Struct`
5. Move rating after `height_cm`
6. Move `height_cm` before `weight_kg`
7. Move `height_cm` to end of table
8. Move `nationality` to index 5
9. Move `first_name` to Start of table
10. Rename `date_of_birth` to `birth_date`
11. Sort column `A` by Ascending
12. Change type of `is_present` to `Boolean`
13. Change type of `hourly_rate` to `Number`

Si vous devez apporter une modification, vous pouvez le faire dans le volet d'aperçu en prévisualisant le résultat de chaque étape, en annulant une étape et en réorganisant les étapes. Par exemple :

- Annuler/rétablir une étape : annulez une étape en cliquant sur l'icône Annuler. Vous pouvez répéter une étape en choisissant l'icône de rétablissement.



- Étape de réorganisation : lorsque vous réorganisez une étape, AWS Glue Studio chaque étape est validée et vous indique si l'étape n'est pas valide.
8. Une fois que vous avez appliqué une étape, le panneau Transformation affiche toutes les étapes de votre recette. Vous pouvez effacer toutes les étapes pour recommencer, ajouter d'autres étapes en cliquant sur l'icône d'ajout ou choisir Terminer la création de la recette.

The screenshot displays the AWS Glue Studio 'visual-mode' interface. On the left, the 'Preview' pane shows a table with 23 columns and 259 rows. The columns include 'id', 'name', 'age', 'sex', 'height_cm', 'weight_kg', 'nationality', 'date_of_birth', and 'hourly_rate'. The right pane, titled 'Transform', shows a 'Recipe' section with a list of 13 steps for a 'Data Cleanup Recipe'. A red box highlights the 'Save' button in the top right corner of the interface.

9. Choisissez Enregistrer en haut à droite de votre écran. Les étapes de votre recette ne seront pas enregistrées tant que vous n'aurez pas enregistré votre travail.

Importer une AWS Glue DataBrew recette dans AWS Glue Studio

Dans AWS Glue DataBrew, une recette est un ensemble d'étapes de transformation de données. AWS Glue DataBrew recipes décrit comment transformer des données déjà lues et ne décrit pas où et comment lire les données, ni comment et où écrire des données. Ceci est configuré dans les nœuds source et cible de AWS Glue Studio. Pour plus d'informations sur les recettes, voir [Création et utilisation de AWS Glue DataBrew recettes](#).

Pour utiliser des AWS Glue DataBrew recettes dans AWS Glue Studio, commencez par créer des recettes dans AWS Glue DataBrew. Si vous avez des recettes que vous souhaitez utiliser, vous pouvez ignorer cette étape.

Autorisations IAM pour AWS Glue DataBrew

Cette rubrique fournit des informations pour vous aider à comprendre les actions et les ressources qu'un administrateur IAM peut utiliser dans une politique AWS Identity and Access Management (IAM) pour la transformation de la recette de préparation des données.

Pour plus d'informations sur la sécurité dans AWS Glue, consultez la section [Gestion des accès](#).

Note

Le tableau suivant répertorie les autorisations dont un utilisateur a besoin pour importer une AWS Glue DataBrew recette existante.

Préparation des données : recette, actions de transformation

Action	Description
<code>databrew:ListRecipes</code>	Accorde l'autorisation de récupérer AWS Glue DataBrew des recettes.
<code>databrew:ListRecipeVersions</code>	Accorde l'autorisation de récupérer des versions de AWS Glue DataBrew recettes.
<code>databrew:DescribeRecipe</code>	Accorde l'autorisation de récupérer AWS Glue DataBrew la description de la recette.

Le rôle que vous utilisez pour accéder à cette fonctionnalité doit avoir une politique autorisant plusieurs AWS Glue DataBrew actions. Vous pouvez y parvenir en utilisant la `AWSGlueConsoleFullAccess` politique qui inclut les actions nécessaires ou en ajoutant la politique en ligne suivante à votre rôle :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
```

```
        "databrew:ListRecipes",
        "databrew:ListRecipeVersions",
        "databrew:DescribeRecipe"
    ],
    "Resource": [
        "*"
    ]
}
]
```

Pour utiliser la transformation Recette de préparation des données, vous devez ajouter l'action `IAM:PassRole` à la politique d'autorisation.

Autorisations supplémentaires requises

Action	Description
<code>iam:PassRole</code>	Permet à IAM d'autoriser l'utilisateur à transmettre les rôles approuvés.

Sans ces autorisations, l'erreur suivante se produit :

```
"errorCode": "AccessDenied"
"errorMessage": "User: arn:aws:sts::account_id:assumed-role/AWSGlueServiceRole is not
authorized to perform: iam:PassRole on resource: arn:aws:iam::account_id:role/service-
role/AWSGlueServiceRole
because no identity-based policy allows the iam:PassRole action"
```


Importer une AWS Glue DataBrew recette

Pour importer une AWS Glue DataBrew recette et l'utiliser dans AWS Glue Studio:

Si vous possédez déjà un nœud de recette de préparation des données et que vous souhaitez modifier les étapes de la recette directement dans celui-ci AWS Glue Studio, vous devrez les importer dans votre AWS Glue Studio tâche.

1. Démarrez un AWS Glue emploi dans AWS Glue Studio avec une source de données.

2. Ajoutez le nœud Data Preparation Recipe au canevas des tâches.



3. Dans le panneau Transformation, saisissez le nom de votre recette.
4. Choisissez un ou plusieurs nœuds parents en sélectionnant les nœuds disponibles sur le canevas dans la liste déroulante.
5. Choisissez Author Recipe. Si Author Recipe est gris, elle n'est pas disponible tant que les nœuds parents n'ont pas été sélectionnés et qu'une session de prévisualisation des données n'est pas terminée.

Transform



Author Data Preparation Recipe

Author Recipe

Name

Data Preparation Recipe

Node parents

Choose which nodes will provide inputs for this one.

Choose one or more parent node



Plans



S3 - DataSource

||

6. Le bloc de données se charge et affiche des informations détaillées sur vos données sources.

Sélectionnez l'icône Autres actions et choisissez Importer la recette.

Transform



Authoring Data Preparation Recipe

Done authoring recipe



Recipe (0)



Import recipe




Build your Recipe

Start applying transformation steps to your data. All your data preparation steps will be tracked in the recipe.




Add step


- Utilisez l'assistant d'importation de recettes pour effectuer les étapes. À l'étape 1, recherchez votre recette, sélectionnez-la, puis cliquez sur Suivant.




8. À l'étape 2, choisissez vos options d'importation. Vous pouvez choisir d'ajouter une nouvelle recette à une recette existante ou de remplacer une recette existante. Choisissez Suivant.



9. À l'étape 3, validez les étapes de la recette. Une fois que vous avez importé votre AWS Glue DataBrew recette, vous pouvez la modifier directement dans AWS Glue Studio.





10. Ensuite, les étapes seront importées dans le cadre de votre AWS Glue travail. Apportez les modifications de configuration nécessaires dans l'onglet Détails de la tâche, par exemple en nommant votre tâche et en ajustant la capacité allouée selon les besoins. Choisissez Enregistrer pour enregistrer votre travail et votre recette.

 Note

JOIN, UNION, GROUP_BY, PIVOT, UNPIVOT, TRANSPOSE ne sont pas pris en charge pour l'importation de recettes et ne seront pas non plus disponibles en mode de création de recettes.

11. Vous pouvez éventuellement terminer la création de la tâche en ajoutant d'autres nœuds de transformation selon vos besoins et en ajoutant des nœuds cibles de données.

Si vous réorganisez les étapes après avoir importé une recette AWS Glue, validez ces étapes. Par exemple, si vous renommez puis supprimez une colonne et que vous déplacez l'étape de suppression vers le haut, l'étape de renommage ne sera pas valide. Vous pouvez ensuite modifier les étapes pour corriger l'erreur de validation.

Migration depuis AWS Glue DataBrew vers AWS Glue Studio

Si vous avez des recettes AWS Glue DataBrew, utilisez la liste de contrôle suivante pour migrer vos recettes vers AWS Glue Studio.

Si tu veux	Procédez comme suit
Permettez aux utilisateurs de récupérer AWS Glue DataBrew des recettes, des versions de recettes et des descriptions de recettes.	Ajoutez des autorisations IAM à une politique qui permet à votre rôle d'accéder aux actions nécessaires. Consultez Autorisations IAM pour AWS Glue DataBrew .
Importez une AWS Glue DataBrew recette existante dans AWS Glue Studio.	Suivez les étapes de Importer une AWS Glue DataBrew recette .
Importez une recette avec JOIN et UNION.	Les recettes comportant des transformations UNION et JOIN ne sont pas prises en charge. Utilisez les transformations Join et Union dans AWS Glue Studio avant ou après un nœud Data Preparation Recipe.

Utilisation de Modifier le schéma pour remapper les clés de propriétés de données

Une transformation Modifier le schéma remet les clés de propriété de données source dans la configuration souhaitée pour les données cibles. Dans un nœud de transformation Modifier le schéma, vous pouvez :

- Modifiez le nom de plusieurs clés de propriété de données.
- Modifiez le type de données des clés de propriété de données, si le nouveau type de données est pris en charge et qu'il existe un chemin de transformation entre les deux types de données.
- Choisir un sous-ensemble de clés de propriété de données en indiquant les clés de propriété de données que vous souhaitez supprimer.

Vous pouvez également ajouter des nœuds Change Schema supplémentaires au diagramme de tâches selon vos besoins, par exemple pour modifier des sources de données supplémentaires ou à la suite d'une transformation de jointure.

Utilisation du schéma de modification avec un type de données décimal

Lorsque vous utilisez la transformation Change Schema avec un type de données décimal, la transformation Change Schema modifie la précision à la valeur par défaut de (10,2). Pour modifier

cela et définir la précision adaptée à votre cas d'utilisation, vous pouvez utiliser la transformation de requête SQL et convertir les colonnes avec une précision spécifique.

Par exemple, si vous avez une colonne d'entrée nommée « DecimalCol » de type Décimal et que vous souhaitez la remapper en une colonne de sortie nommée « OutputDecimalCol » avec une précision spécifique de (18,6), vous devez :

1. Ajoutez une transformation de requête SQL suivante après la transformation de schéma de modification.
2. Dans la transformation de requête SQL, utilisez une requête SQL pour convertir la colonne remappée avec la précision souhaitée. La requête SQL ressemblerait à ceci :

```
SELECT col1, col2, CAST(DecimalCol AS DECIMAL(18,6)) AS OutputDecimalCol
FROM __THIS__
```

Dans la requête SQL ci-dessus :

- `col1` et `col2` sont d'autres colonnes de vos données que vous souhaitez transmettre sans modification.
- `DecimalCol` est le nom de colonne d'origine issu des données d'entrée.
- `CAST (DecimalCol AS DECIMAL (18,6))` convertit le `DecimalCol` en un type décimal avec une précision de 18 chiffres et 6 décimales.
- `AS OutputDecimalCol` renomme la colonne castée en `OutputDecimalCol`.

En utilisant la transformation SQL Query, vous pouvez remplacer la précision par défaut définie par la transformation Change Schema et convertir explicitement les colonnes décimales à la précision souhaitée. Cette approche vous permet de tirer parti de la transformation Change Schema pour renommer et restructurer vos données tout en gérant les exigences de précision pour les colonnes décimales lors de la transformation de requête SQL ultérieure.

Ajouter une transformation Change Schema à votre tâche

Note

La transformation Modifier le schéma n'est pas sensible à la casse.

Pour ajouter un nœud de transformation Modifier le schéma à votre diagramme de tâche

1. (Facultatif) Ouvrez le panneau Ressources, puis choisissez Modifier le schéma pour ajouter une nouvelle transformation à votre diagramme de tâches, si nécessaire.
2. Dans le panneau des propriétés du nœud, saisissez un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste de Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Choisissez l'onglet Transformer dans le volet de propriétés du nœud.
4. Modifiez le schéma d'entrée :
 - Pour renommer une clé de propriété de données, saisissez le nouveau nom de la clé dans le champ Target key (Clé cible).
 - Pour changer le type de données d'une clé de propriété de données, choisissez le nouveau type de données de la clé dans la liste déroulante Data type (Type de données).
 - Pour supprimer une clé de propriété de données du schéma cible, choisissez la case à cocher Drop (Supprimer) pour cette clé.
5. (Facultatif) Après avoir configuré les propriétés du nœud de transformation, vous pouvez afficher le schéma modifié pour vos données en sélectionnant l'onglet Output Schema (Schéma de sortie) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Si vous n'avez pas spécifié de rôle IAM dans le Job détails (Détails de la tâche), vous y êtes invité à ce stade.
6. (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de transformation, vous pouvez prévisualiser le jeu de données modifié en sélectionnant l'onglet Prévisualisation des données dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Il y a un coût associé à l'utilisation de cette fonction, et la facturation commence dès que vous fournissez le rôle IAM.

Utilisation de Supprimer les doublons

La transformation Supprimer les doublons supprime des lignes de votre source de données en vous proposant deux options. Vous pouvez choisir de supprimer les lignes dupliquées qui sont complètement identiques, ou vous pouvez choisir les champs à faire correspondre et ne supprimer que les lignes basées sur ces champs.

Par exemple, dans ce jeu de données, vous avez des lignes dupliquées où toutes les valeurs de certaines lignes sont exactement identiques à celles d'une autre ligne, et certaines valeurs des lignes sont identiques ou différentes.

Rangée	Nom	E-mails	Age	État	Remarque
1	Joy	joy@gmail	33	NY	
2	Tim	tim@gmail	45	OH	
3	Rose	rose@gmail	23	NJ	
4	Tim	tim@gmail	42	OH	
5	Rose	rose@gmail	23	NJ	
6	Tim	tim@gmail	42	OH	Il s'agit d'une ligne dupliquée qui correspond parfaitement à toutes les valeurs de la ligne n° 4
7	Rose	rose@gmail	23	NJ	Il s'agit d'une ligne dupliquée qui correspond parfaitement à toutes les valeurs de la ligne n° 5

Si vous choisissez de faire correspondre des lignes entières, les lignes 6 et 7 seront supprimées du jeu de données. Le jeu de données est désormais le suivant :

Rangée	Nom	E-mails	Age	État
1	Joy	joy@gmail	33	NY
2	Tim	tim@gmail	45	OH
3	Rose	rose@gmail	23	NJ
4	Tim	tim@gmail	42	OH
5	Rose	rose@gmail	23	NJ

Si vous avez choisi de spécifier des clés, vous pouvez choisir de supprimer les lignes correspondant à « name » et « email ». Cela vous permet de mieux contrôler ce qu'est une « ligne dupliquée » pour votre jeu de données. En spécifiant « name » et « email », le jeu de données est désormais le suivant :

Rangée	Nom	E-mails	Age	État
1	Joy	joy@gmail	33	NY
2	Tim	tim@gmail	45	OH
3	Rose	rose@gmail	23	NJ

Quelques points à garder à l'esprit :

- Pour que les lignes soient reconnues comme des doublons, les valeurs sont sensibles à la casse. Toutes les valeurs des lignes doivent avoir la même casse. Cela s'applique à l'une ou l'autre des options que vous choisissez (Faire correspondre des lignes entières ou Spécifier des clés).
- Toutes les valeurs sont lues sous forme de chaînes.
- La transformation Supprimer les doublons utilise la commande Spark dropDuplicates.
- Lorsque vous utilisez la transformation Supprimer les doublons, la première ligne est conservée et les autres lignes sont supprimées.

- La transformation Supprimer les doublons ne modifie pas le schéma de la trame de données. Si vous choisissez de spécifier des clés, tous les champs sont conservés dans la trame de données obtenue.

Utilisation SelectFields pour supprimer la plupart des clés de propriété des données

Vous pouvez créer un sous-ensemble de clés de propriétés de données à partir de l'ensemble de données à l'aide de la SelectFieldstransformation. Vous indiquez quelles clés de propriété de données vous souhaitez conserver et les autres sont supprimées du jeu de données.

Note

La SelectFieldstransformation distingue les majuscules et minuscules. À utiliser ApplyMappingsi vous avez besoin d'une méthode qui ne distingue pas les majuscules des minuscules pour sélectionner les champs.

Pour ajouter un nœud de SelectFields transformation à votre diagramme de tâches

1. (Facultatif) Ouvrez le panneau Ressources, puis choisissez SelectFieldsd'ajouter une nouvelle transformation à votre diagramme de tâches, si nécessaire.
2. Sur la page Node properties (Propriétés de nœud) au cours de la tâche, saisissez un nom pour le nœud dans le diagramme de tâche. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Choisissez l'onglet Transformation dans le volet de détails du nœud.
4. Sous le titre SelectFields, choisissez les clés de propriété des données de l'ensemble de données que vous souhaitez conserver. Toutes autres clés de propriété de données non sélectionnées sont supprimées du jeu de données.

Vous pouvez également cocher la case en regard de l'en-tête de colonne Field (Champ) pour choisir automatiquement toutes les clés de propriété de données dans le jeu de données. Vous pouvez ensuite désélectionner des clés de propriété de données individuelles pour les supprimer du jeu de données.

5. (Facultatif) Après avoir configuré les propriétés du nœud de transformation, vous pouvez afficher le schéma modifié pour vos données en sélectionnant l'onglet Output Schema (Schéma de sortie) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un

nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Si vous n'avez pas spécifié de rôle IAM dans le Job détails (Détails de la tâche), vous y êtes invité à ce stade.

6. (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de transformation, vous pouvez prévisualiser le jeu de données modifié en sélectionnant l'onglet Prévisualisation des données dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Il y a un coût associé à l'utilisation de cette fonction, et la facturation commence dès que vous fournissez le rôle IAM.

Utilisation DropFields pour conserver la plupart des clés de propriété des données

Vous pouvez créer un sous-ensemble de clés de propriétés de données à partir de l'ensemble de données à l'aide de la DropFieldstransformation. Vous indiquez les clés de propriété des données que vous souhaitez supprimer du jeu de données et le reste des clés est conservé.

Note

La DropFieldstransformation distingue les majuscules et minuscules. Utilisez Modifier le schéma si vous avez besoin d'une méthode non sensible à la casse pour sélectionner des champs.

Pour ajouter un nœud de DropFields transformation à votre diagramme de tâches

1. (Facultatif) Ouvrez le panneau Ressources, puis choisissez DropFieldsd'ajouter une nouvelle transformation à votre diagramme de tâches, si nécessaire.
2. Sur la page Node properties (Propriétés de nœud) au cours de la tâche, saisissez un nom pour le nœud dans le diagramme de tâche. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Choisissez l'onglet Transformation dans le volet de détails du nœud.
4. Sous le titre DropFields, choisissez les clés de propriété des données à supprimer de la source de données.

Vous pouvez également cocher la case en regard de l'en-tête de colonne Field (Champ) pour choisir automatiquement toutes les clés de propriété de données dans le jeu de données. Vous

pouvez ensuite désélectionner les clés de propriété de données individuelles afin qu'elles soient conservées dans le jeu de données.

5. (Facultatif) Après avoir configuré les propriétés du nœud de transformation, vous pouvez afficher le schéma modifié pour vos données en sélectionnant l'onglet Output Schema (Schéma de sortie) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Si vous n'avez pas spécifié de rôle IAM dans le Job détails (Détails de la tâche), vous y êtes invité à ce stade.
6. (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de transformation, vous pouvez prévisualiser le jeu de données modifié en sélectionnant l'onglet Prévisualisation des données dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Il y a un coût associé à l'utilisation de cette fonction, et la facturation commence dès que vous fournissez le rôle IAM.

Renommer un champ dans le jeu de données

Vous pouvez utiliser la `RenameFieldTransformation` pour modifier le nom d'une clé de propriété individuelle dans l'ensemble de données.

Note

La `RenameFieldTransformation` distingue les majuscules et minuscules. À utiliser `ApplyMappings` si vous avez besoin d'une transformation qui ne distingue pas les majuscules et minuscules.

Tip

Si vous utilisez la transformation Modifier le schéma, vous pouvez renommer plusieurs clés de propriété de données dans le jeu de données avec une seule transformation.

Pour ajouter un nœud de `RenameField` transformation à votre diagramme de tâches

1. (Facultatif) Ouvrez le panneau Ressources, puis choisissez `RenameField` d'ajouter une nouvelle transformation à votre diagramme de tâches, si nécessaire.

2. Sur la page Node properties (Propriétés de nœud) au cours de la tâche, saisissez un nom pour le nœud dans le diagramme de tâche. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Choisissez l'onglet Transformation.
4. Sous l'en-tête Data field (Champ de données), choisissez une clé de propriété dans les données source, puis entrez un nouveau nom dans le champ New field name (Nom de champ).
5. (Facultatif) Après avoir configuré les propriétés du nœud de transformation, vous pouvez afficher le schéma modifié pour vos données en sélectionnant l'onglet Output Schema (Schéma de sortie) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Si vous n'avez pas spécifié de rôle IAM dans le Job details (Détails de la tâche), vous y êtes invité à ce stade.
6. (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de transformation, vous pouvez prévisualiser le jeu de données modifié en sélectionnant l'onglet Prévisualisation des données dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Il y a un coût associé à l'utilisation de cette fonction, et la facturation commence dès que vous fournissez le rôle IAM.

Utilisation de Spigot pour échantillonner votre jeu de données

Pour tester les transformations effectuées par votre tâche, vous pouvez obtenir un échantillon de données afin de vérifier que la transformation fonctionne comme prévu. La transformation Spigot écrit un sous-ensemble d'enregistrements à partir du jeu de données dans un fichier JSON situé dans un compartiment Amazon S3. La méthode d'échantillonnage des données peut être soit un nombre spécifique d'enregistrements à partir du début du fichier, soit un facteur de probabilité utilisé pour choisir les enregistrements.

Pour ajouter un nœud de transformation Spigot à votre diagramme de tâche

1. (Facultatif) Ouvrez le panneau Ressources, puis choisissez Spigot pour ajouter une nouvelle transformation à votre diagramme de tâches, si nécessaire.
2. Sur la page Node properties (Propriétés de nœud) au cours de la tâche, saisissez un nom pour le nœud dans le diagramme de tâche. Si aucun parent de nœud n'est déjà sélectionné,

choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.

3. Choisissez l'onglet Transformation dans le volet de détails du nœud.
4. Saisissez un chemin d'accès Amazon S3 ou choisissez Browse S3 (Parcourir S3) pour choisir un emplacement dans Amazon S3. C'est l'emplacement où la tâche écrit le fichier JSON qui contient l'échantillon de données.
5. Saisissez les informations relatives à la méthode d'échantillonnage. Vous pouvez spécifier une valeur pour le Number of records (Nombre d'enregistrements) à écrire en commençant par le début du jeu de données et un Probability threshold (Seuil de probabilité) (saisi comme une valeur décimale avec une valeur maximale de 1) permettant de choisir un enregistrement donné.

Par exemple, pour écrire les 50 premiers enregistrements du jeu de données, vous devez définir le Number of records (Nombre d'enregistrements) à 50 et le Probability threshold (Seuil de probabilité) à 1 (100%).

Joindre des jeux de données

La transformation Join permet de joindre deux jeux de données en un seul. Vous spécifiez les noms de clé dans le schéma de chaque jeu de données à comparer. Le résultat `DynamicFrame` contient des lignes où les clés répondent à la condition de jointure. Les lignes de chaque jeu de données qui répondent à la condition de jointure sont combinées en une seule ligne dans le résultat en sortie `DynamicFrame`, qui contient toutes les colonnes de l'un ou l'autre des jeux de données.

Pour ajouter un nœud de transformation Join à votre diagramme de tâche

1. Si une seule source de données est disponible, vous devez ajouter un nouveau nœud de source de données au diagramme de tâche.
2. Choisissez l'un des nœuds source pour la jointure. Ouvrez le panneau Ressources, puis choisissez Jointure pour ajouter une nouvelle transformation à votre diagramme de tâches.
3. Sur la page Node properties (Propriétés de nœud) au cours de la tâche, saisissez un nom pour le nœud dans le diagramme de tâche.
4. Dans l'onglet Node properties (Propriétés de nœud), sous l'en-tête Node parents (Parents de nœud), ajoutez un nœud parent de sorte qu'il y ait deux jeux de données fournissant des entrées pour la jointure. Le parent peut être un nœud de source de données ou un nœud de transformation.

 Note

Une jointure ne peut avoir que deux nœuds parents.

5. Choisissez l'onglet Transformation.

Si vous voyez un message indiquant qu'il y a des noms de clés en conflit, vous pouvez :

- Choisissez Resolve it pour ajouter automatiquement un nœud de ApplyMappingtransformation à votre diagramme de tâches. Le ApplyMapping nœud ajoute un préfixe à toutes les clés de l'ensemble de données portant le même nom qu'une clé de l'autre ensemble de données. Par exemple, si vous utilisez la valeur par défaut **right**, toutes les clés du jeu de données de droite ayant le même nom qu'une clé dans le jeu de données de gauche seront renommées en `(right)key name`.
- Ajouter manuellement un nœud de transformation plus tôt dans le diagramme de tâches pour supprimer ou renommer les clés en conflit.

6. Choisir le type de jointure dans la liste Join type (Type de jointure).

- Inner join (Jointure interne ou intérieure) : renvoie une ligne contenant des colonnes des deux jeux de données pour chaque correspondance en fonction de la condition de jointure. Les lignes qui ne satisfont pas à la condition de jointure ne sont pas renvoyées.
- Left join (Jointure gauche) : toutes les lignes du jeu de données de gauche et seules les lignes du jeu de données de droite qui satisfont à la condition de jointure.
- Right join (Joindre à droite) : toutes les lignes du jeu de données de droite et uniquement les lignes du jeu de données de gauche qui satisfont à la condition de jointure.
- Outer join (Jointure externe ou extérieure) : toutes les lignes des deux jeux de données.
- Left semi join (Semi-jointure gauche) : toutes les lignes du jeu de données de gauche qui ont une correspondance dans le jeu de données de droite en fonction de la condition de jointure.
- Left anti join (Anti-jointure gauche) : toutes les lignes du jeu de données de gauche qui n'ont pas de correspondance dans le jeu de données de droite en fonction de la condition de jointure.

7. Sur l'onglet Transformation, sous l'en-tête Join conditions (Conditions de jointure), choisissez Add condition (Ajouter une condition). Choisissez une clé de propriété dans chaque jeu de données à comparer. Les clés de propriété sur le côté gauche de l'opérateur de comparaison

sont appelées le jeu de données gauche et les clés de propriété à droite sont appelées le jeu de données de droite.

Pour des conditions de jointure plus complexes, vous pouvez ajouter des clés correspondantes supplémentaires en sélectionnant Add condition (Ajouter une condition) plus d'une fois. Si vous ajoutez accidentellement une condition, vous pouvez choisir l'icône de suppression



pour la supprimer.

8. (Facultatif) Après avoir configuré les propriétés du nœud de transformation, vous pouvez afficher le schéma modifié pour vos données en sélectionnant l'onglet Output Schema (Schéma de sortie) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Si vous n'avez pas spécifié de rôle IAM dans le Job détails (Détails de la tâche), vous y êtes invité à ce stade.
9. (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de transformation, vous pouvez prévisualiser le jeu de données modifié en sélectionnant l'onglet Prévisualisation des données dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Il y a un coût associé à l'utilisation de cette fonctionnalité, et la facturation commence dès que vous fournissez le rôle IAM.

Pour un exemple de schéma de sortie de jointure, considérez une jointure entre deux jeux de données avec les clés de propriété suivantes :

```
Left: {id, dept, hire_date, salary, employment_status}
Right: {id, first_name, last_name, hire_date, title}
```

La jointure est configurée pour correspondre aux clés `id` et `hire_date` en utilisant l'opérateur de comparaison `=`.

Parce que les deux jeux de données contiennent les clés `id` et `hire_date`, vous avez choisi Resolve it (Résoudre les problèmes) pour ajouter automatiquement le préfixe **right** aux clés du jeu de données approprié.

Les clés dans le schéma de sortie seraient :

```
{id, dept, hire_date, salary, employment_status,
```

```
(right)id, first_name, last_name, (right)hire_date, title}
```

Utiliser Union pour combiner des lignes

Vous utilisez le nœud de transformation Union lorsque vous souhaitez combiner des lignes provenant de plusieurs sources de données ayant le même schéma.

Il existe deux types de transformations Union :

1. ALL : lorsque vous appliquez ALL, l'union qui en résulte ne supprime pas les lignes en double.
2. DISTINCT : lorsque vous appliquez DISTINCT, l'union qui en résulte supprime les lignes dupliquées.

Unions vs. jointures

Vous utilisez Union pour combiner des lignes. Vous utilisez Jointure pour combiner des colonnes.

Utilisation de la transformation Union dans le canevas ETL visuel

1. Ajoutez plusieurs sources de données pour effectuer une transformation Union. Pour ajouter une source de données, ouvrez le panneau Ressources, puis sélectionnez la source de données dans l'onglet Sources. Avant d'utiliser la transformation Union, vous devez vous assurer que toutes les sources de données impliquées dans l'union ont le même schéma et la même structure.
2. Lorsque vous souhaitez combiner au moins deux sources de données à l'aide de la transformation Union, créez la transformation Union en l'ajoutant au canevas. Ouvrez le panneau Ressources sur le canevas et recherchez « Union ». Vous pouvez également choisir l'onglet Transformer dans le panneau Ressources et faire défiler la page vers le bas jusqu'à ce que vous trouviez la transformation Union, puis choisir Union.
3. Sélectionnez le nœud Union sur le canevas de la tâche. Dans la fenêtre Propriétés du nœud, choisissez les nœuds parents à connecter à la transformation Union.
4. AWS Glue vérifie la compatibilité pour s'assurer que la transformation de l'Union peut être appliquée à toutes les sources de données. Si le schéma des sources de données est identique, l'opération sera autorisée. Si les sources de données n'ont pas le même schéma, un message d'erreur non valide s'affiche : « Les schémas d'entrée de cette union ne sont pas identiques. Envisagez ApplyMapping de l'utiliser pour faire correspondre les schémas. » Pour résoudre ce problème, choisissez Utiliser ApplyMapping.
5. Choisissez le type d'union.

1. All : par défaut, le type d'union All est sélectionné ; cela entraînera des lignes dupliquées s'il y en a dans la combinaison de données.
2. Distinct : choisissez Distinct si vous souhaitez que les lignes dupliquées soient supprimées de la combinaison de données résultante.

Utilisation SplitFields pour diviser un ensemble de données en deux

La SplitFieldstransformation vous permet de choisir certaines des clés de propriété des données dans le jeu de données en entrée et de les placer dans un ensemble de données et les clés non sélectionnées dans un ensemble de données distinct. Le résultat de cette transformation est une collection de DynamicFrames.

Note

Vous devez utiliser une SelectFromCollectiontransformation pour convertir la collection de DynamicFrames en une seule DynamicFrame avant de pouvoir envoyer la sortie vers un emplacement cible.

La SplitFieldstransformation distingue les majuscules et minuscules. Ajoutez une ApplyMappingtransformation en tant que nœud parent si vous avez besoin de noms de clés de propriété qui ne distinguent pas les majuscules et minuscules.

Pour ajouter un nœud de SplitFields transformation à votre diagramme de tâches

1. (Facultatif) Ouvrez le panneau Ressources, puis choisissez SplitFieldsd'ajouter une nouvelle transformation à votre diagramme de tâches, si nécessaire.
2. Sur la page Node properties (Propriétés de nœud) au cours de la tâche, saisissez un nom pour le nœud dans le diagramme de tâche. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Choisissez l'onglet Transformation.
4. Choisissez les clés de propriété que vous souhaitez placer dans le premier jeu de données. Les clés que vous ne choisissez pas sont placées dans le deuxième jeu de données.
5. (Facultatif) Après avoir configuré les propriétés du nœud de transformation, vous pouvez afficher le schéma modifié pour vos données en sélectionnant l'onglet Output Schema (Schéma de

sortie) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Si vous n'avez pas spécifié de rôle IAM dans le Job détails (Détails de la tâche), vous y êtes invité à ce stade.

6. (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de transformation, vous pouvez prévisualiser le jeu de données modifié en sélectionnant l'onglet Prévisualisation des données dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Il y a un coût associé à l'utilisation de cette fonction, et la facturation commence dès que vous fournissez le rôle IAM.
7. Configurez un nœud de `SelectFromCollection` transformation pour traiter les ensembles de données résultants.

Présentation d'un transformation `SelectFromCollection`

Certaines transformations ont plusieurs ensembles de données en sortie au lieu d'un seul ensemble de données, `SplitFields` par exemple. La `SelectFromCollection` transformation sélectionne un ensemble de données (`DynamicFrame`) parmi une collection d'ensembles de données (un tableau de `DynamicFrames`). Le résultat de la transformation est la `DynamicFrame`.

Vous devez utiliser cette transformation après avoir utilisé une transformation qui crée une collection de `DynamicFrames`, tels que :

- Transformations de code personnalisé
- `SplitFields`

Si vous n'ajoutez aucun nœud de `SelectFromCollection` transformation à votre diagramme de tâches après l'une de ces transformations, vous obtiendrez une erreur pour votre tâche.

Le nœud parent de cette transformation doit être un nœud qui renvoie une collection de `DynamicFrames`. Si vous choisissez un parent pour ce nœud de transformation qui renvoie un seul `DynamicFrame`, comme `Join`, votre tâche renvoie une erreur.

De même, si vous utilisez un `SelectFromCollection` nœud dans votre diagramme de tâches comme parent pour une transformation qui attend un nœud unique `DynamicFrame` en entrée, votre tâche renvoie une erreur.

Node parents

Select which node(s) will provide inputs for this one

Split Fields
SplitFields - Transform



 Parent node Split Fields outputs a collection, but node Drop Fields does not accept a collection.

Utilisation SelectFromCollection pour choisir le jeu de données à conserver

Utilisez la `SelectFromCollection` transformation pour convertir une collection de `DynamicFrames` en une seule `DynamicFrame`.

Pour ajouter un nœud de `SelectFromCollection` transformation à votre diagramme de tâches

1. (Facultatif) Ouvrez le panneau Ressources, puis choisissez `SelectFromCollection` d'ajouter une nouvelle transformation à votre diagramme de tâches, si nécessaire.
2. Sur la page Node properties (Propriétés de nœud) au cours de la tâche, saisissez un nom pour le nœud dans le diagramme de tâche. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Choisissez l'onglet Transformation.
4. Sous l'en-tête Frame index (Index de l'image), choisissez le numéro d'index du tableau qui correspond au `DynamicFrame` que vous souhaitez sélectionner dans la collection de `DynamicFrames`.

Par exemple, si le nœud parent de cette transformation est une `SplitFields` transformation, dans l'onglet Schéma de sortie de ce nœud, vous pouvez voir le schéma de chaque transformation `DynamicFrame`. Si vous souhaitez conserver le `DynamicFrame` associé au schéma de Sortie 2, vous pouvez choisir **1** pour la valeur de Frame index (Index de l'image), qui est la deuxième valeur de la liste.

Seul le `DynamicFrame` que vous choisissez est inclus dans le résultat.

5. (Facultatif) Après avoir configuré les propriétés du nœud de transformation, vous pouvez afficher le schéma modifié pour vos données en sélectionnant l'onglet Output Schema (Schéma de sortie) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Si vous

n'avez pas spécifié de rôle IAM dans le Job détails (Détails de la tâche), vous y êtes invité à ce stade.

6. (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de transformation, vous pouvez prévisualiser le jeu de données modifié en sélectionnant l'onglet Prévisualisation des données dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Il y a un coût associé à l'utilisation de cette fonction, et la facturation commence dès que vous fournissez le rôle IAM.

Rechercher et remplir les valeurs manquantes dans un jeu de données

Vous pouvez utiliser la FillMissingValues transformation pour localiser les enregistrements de l'ensemble de données qui contiennent des valeurs manquantes et ajouter un nouveau champ dont la valeur est déterminée par imputation. Le jeu de données source est utilisé pour entraîner le modèle de machine learning (ML) qui détermine la valeur manquante. Si vous utilisez des jeux de données incrémentiels, chacun d'entre eux est utilisé comme données d'entraînement pour le modèle ML, de sorte que les résultats peuvent ne pas être aussi précis.

Pour utiliser un nœud de FillMissingValues transformation dans votre diagramme de tâches

1. (Facultatif) Ouvrez le panneau Ressources, puis choisissez FillMissingValues d'ajouter une nouvelle transformation à votre diagramme de tâches, si nécessaire.
2. Sur la page Node properties (Propriétés de nœud) au cours de la tâche, saisissez un nom pour le nœud dans le diagramme de tâche. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste de Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Choisissez l'onglet Transformation.
4. Pour Data field (Champ de données), choisissez le nom de la colonne ou du champ dans les données source que vous souhaitez analyser pour les valeurs manquantes.
5. (Facultatif) Dans la section New field name (Nouveau nom de champ), saisissez un nom pour le champ ajouté à chaque enregistrement qui contiendra la valeur de remplacement estimée du champ analysé. Si le champ analysé n'a pas de valeur manquante, la valeur du champ analysé est copiée dans le nouveau champ.

Si vous ne spécifiez pas de nom pour le nouveau champ, le nom par défaut est le nom de la colonne analysée, auquel est ajouté `_filled`. Par exemple, si vous entrez **Age** pour Data

- field (Champ de données) et ne spécifiez pas de valeur pour New field name (Nouveau nom de champ), un nouveau champ nommé **Age_filled** est ajouté à chaque enregistrement.
- (Facultatif) Après avoir configuré les propriétés du nœud de transformation, vous pouvez afficher le schéma modifié pour vos données en sélectionnant l'onglet Output Schema (Schéma de sortie) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Si vous n'avez pas spécifié de rôle IAM dans le Job détails (Détails de la tâche), vous y êtes invité à ce stade.
 - (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de transformation, vous pouvez prévisualiser le jeu de données modifié en sélectionnant l'onglet Prévisualisation des données dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Il y a un coût associé à l'utilisation de cette fonction, et la facturation commence dès que vous fournissez le rôle IAM.

Filtrage des clés dans un jeu de données

Utiliser la transformation Filter (Filtrer) pour créer un jeu de données en filtrant les enregistrements du jeu de données source en fonction d'une expression régulière. Les lignes qui ne satisfont pas à la condition de filtre sont retirées du résultat.

- Pour les types de données de chaîne, vous pouvez filtrer les lignes où la valeur clé correspond à une chaîne spécifiée.
- Pour les types de données numériques, vous pouvez filtrer les lignes en comparant la valeur clé à une valeur spécifiée, à l'aide des opérateurs de comparaison <, >, =, !=, <= et >=.

Si vous spécifiez plusieurs conditions de filtrage, les résultats sont combinés à l'aide d'un opérateur AND par défaut, mais vous pouvez choisir OR à la place.

La transformation Filter (Filtrer) est sensible à la casse. Ajoutez une ApplyMappingtransformation en tant que nœud parent si vous avez besoin de noms de clés de propriété qui ne distinguent pas les majuscules et minuscules.

Pour ajouter un nœud de transformation de filtre à votre diagramme de tâche

- (Facultatif) Ouvrez le panneau Ressources, puis choisissez Filtrer pour ajouter une nouvelle transformation à votre diagramme de tâches, si nécessaire.

2. Sur la page Node properties (Propriétés de nœud) au cours de la tâche, saisissez un nom pour le nœud dans le diagramme de tâche. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parent de nœud) à utiliser comme source pour la transformation.
3. Choisissez l'onglet Transformation.
4. Choisissez soit ET global, soit OU global. Cela détermine la façon dont plusieurs conditions de filtrage sont combinées. Toutes les conditions sont combinées en utilisant les opérations AND ou OR. Si vous n'avez qu'une seule condition de filtre, vous pouvez choisir l'une ou l'autre.
5. Cliquez sur le bouton Add condition (Ajouter une condition) dans la section Filter condition (Condition de filtrage) pour ajouter une condition de filtre.

Dans le champ Key (Clé), choisissez un nom de clé de propriété dans le jeu de données. Dans le champ Opération, choisissez l'opérateur de comparaison. Dans le champ Valeur, saisissez la valeur de comparaison. Voici quelques exemples de conditions de filtrage :

- `year >= 2018`
- `State matches 'CA*'`

Lorsque vous filtrez des valeurs de chaîne, assurez-vous que la valeur de comparaison utilise un format d'expression régulière qui correspond au langage de script sélectionné dans les propriétés de la tâche (Python ou Scala).

6. Ajoutez des conditions de filtrage supplémentaires, si nécessaire.
7. (Facultatif) Après avoir configuré les propriétés du nœud de transformation, vous pouvez afficher le schéma modifié pour vos données en sélectionnant l'onglet Output Schema (Schéma de sortie) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Si vous n'avez pas spécifié de rôle IAM dans le Job détails (Détails de la tâche), vous y êtes invité à ce stade.
8. (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de transformation, vous pouvez prévisualiser le jeu de données modifié en sélectionnant l'onglet Prévisualisation des données dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Il y a un coût associé à l'utilisation de cette fonction, et la facturation commence dès que vous fournissez le rôle IAM.

Utilisation DropNullFields pour supprimer des champs contenant des valeurs nulles

Utilisez la DropNullFieldstransformation pour supprimer des champs de l'ensemble de données si toutes les valeurs du champ sont « nulles ». Par défaut, AWS Glue Studio reconnaîtra les objets nuls, mais certaines valeurs telles que les chaînes vides, les chaînes « nulles », les entiers -1 ou d'autres espaces réservés tels que les zéros ne sont pas automatiquement reconnues comme nulles.

Pour utiliser le DropNullFields

1. Ajoutez un DropNullFields nœud au diagramme des tâches.
2. Dans la page Node properties (Propriétés de nœud), choisissez des valeurs supplémentaires qui représentent une valeur null. Vous pouvez choisir de sélectionner aucune valeur ou la totalité des valeurs :

The screenshot shows the 'Node properties' tab for the 'DropNullFields' transformation. The title is 'DropNullFields' with an 'Info' icon. Below the title is the description: 'Remove fields or columns where all the values are the null objects.' A sub-header reads 'Choose additional values that represent a null value below.' There are three checkboxes: 'Empty String ("" or "")', '"null" String', and '-1 Integer'. Below these is a section titled 'Add custom null values' with the instruction 'Specify custom null values by entering the value and choosing the datatype.' This section contains a text input field with the placeholder 'Enter value', a dropdown menu currently set to 'String', and a trash icon. At the bottom of this section is a button labeled 'Add new value'.

- Chaîne vide (« » ou "") – les champs contenant des chaînes vides seront supprimés
 - « Chaîne null » – les champs contenant la chaîne avec le mot « null » seront supprimés
 - Entier -1 – les champs contenant un entier -1 (un négatif) seront supprimés
3. Au besoin, vous pouvez également spécifier des valeurs null personnalisées. Il s'agit de valeurs null qui peuvent être uniques à votre jeu de données. Pour ajouter une valeur null personnalisée, choisissez Add new value (Ajouter une nouvelle valeur).

4. Entrez la valeur null personnalisée. Par exemple, il peut s'agir de zéro ou de toute valeur utilisée pour représenter une valeur null dans le jeu de données.
5. Choisissez le type de données dans le champ déroulant. Les types de données peuvent être soit des chaînes, soit des nombres entiers.

 Note

Les valeurs null personnalisées et leurs types de données doivent correspondre exactement pour que les champs soient reconnus comme des valeurs null et que les champs soient supprimés. Les correspondances partielles où seule la valeur null personnalisée correspond, mais pas le type de données, n'entraîneront pas la suppression des champs.

Utilisation d'une requête SQL pour transformer des données

Vous pouvez utiliser une transformation SQL pour écrire votre propre transformation sous la forme d'une requête SQL.

Un nœud de transformation SQL peut avoir plusieurs jeux de données source, mais ne produit qu'un seul jeu de données en sortie. Dans contient un champ de texte, dans lequel vous saisissez la requête Apache SparkSQL. Vous pouvez attribuer des alias à chaque jeu de données utilisé en entrée, pour contribuer à simplifier la requête SQL. Pour plus d'informations sur la syntaxe SQL, veuillez consulter la [documentation Spark SQL](#).

 Note

Si vous utilisez une transformation SQL Spark avec une source de données située dans un VPC, ajoutez un AWS Glue Point de terminaison du VPC vers le VPC qui contient la source de données. Pour plus d'informations sur la configuration des points de terminaison de développement, veuillez consulter les rubriques [Ajout d'un point de terminaison de développement](#), [Configuration de votre environnement pour les points de terminaison de développement](#), et [Accès à votre point de terminaison de développement](#) dans le Guide du développeur AWS Glue .

Pour utiliser un nœud de transformation SQL dans votre diagramme de tâche

1. (Facultatif) Ajoutez un nœud de transformation au diagramme de tâche, si nécessaire. Choisissez SQL Query pour le type de nœud.

Note

Si vous utilisez une session d'aperçu des données et un code SQL personnalisé ou un nœud de code personnalisé, la session d'aperçu des données exécutera le code SQL ou le bloc de code tel quel pour l'ensemble de données.

2. Sur la page Node properties (Propriétés de nœud) au cours de la tâche, saisissez un nom pour le nœud dans le diagramme de tâche. Si un parent de nœud n'est pas déjà sélectionné ou si vous souhaitez plusieurs entrées pour la transformation SQL, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation. Ajoutez d'autres nœuds parents si nécessaire.
3. Choisissez l'onglet Transformation dans le volet de détails du nœud.
4. Les jeux de données source de la requête SQL sont identifiés par les noms que vous avez spécifiés dans le champ Name (Nom) de chaque nœud. Si vous ne souhaitez pas utiliser ces noms, ou si les noms ne conviennent pas à une requête SQL, vous pouvez associer un nom à chaque jeu de données. La console fournit des alias par défaut, tels que MyDataSource.

Par exemple, si un nœud parent du nœud de transformation SQL est nommé `Rename Org PK field`, vous pouvez associer le nom `org_table` à ce jeu de données. Cet alias peut ensuite être utilisé dans la requête SQL à la place du nom du nœud.

5. Dans le champ de saisie de texte sous l'en-tête Bloc de code, collez ou saisissez la requête SQL. Le champ de texte affiche la mise en évidence de la syntaxe SQL et des suggestions de mots-clés.
6. Lorsque le nœud de transformation SQL est sélectionné, choisissez l'option Schema (Schéma), puis choisissez Edit (Modifier). Indiquez les colonnes et les types de données qui décrivent les champs de sortie de la requête SQL.

Spécifiez le schéma à l'aide des actions suivantes dans la section Output Schema (Schéma de sortie) de la page :

- Pour renommer une colonne, placez le curseur dans la zone Key (Clé) pour la colonne (également appelée field (champ) ou property key (clé de propriété)) et entrez le nouveau nom.
 - Pour modifier le type de données d'une colonne, sélectionnez le nouveau type de données de la colonne dans la liste déroulante.
 - Pour ajouter une nouvelle colonne de niveau supérieur au schéma, choisissez le bouton Overflow (Surcharger) (...), puis choisissez Add root key (Ajouter une clé racine). De nouvelles colonnes sont ajoutées en haut du schéma.
 - Pour supprimer une colonne du schéma, choisissez l'icône de suppression (▢) à l'extrême droite du nom de la clé.
7. Lorsque vous avez terminé de spécifier le schéma en sortie, choisissez Apply (Appliquer) pour enregistrer vos modifications et quittez l'éditeur de schéma. Si vous ne souhaitez pas enregistrer de modifications, choisissez Cancel (Annuler) pour quitter l'éditeur de schéma.
 8. (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de transformation, vous pouvez prévisualiser le jeu de données modifié en sélectionnant l'onglet Prévisualisation des données dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Il y a un coût associé à l'utilisation de cette fonction, et la facturation commence dès que vous fournissez le rôle IAM.

Utilisation de Agrégation pour effectuer des calculs récapitulatifs sur des champs sélectionnés

Pour utiliser Aggregate transform (transformation d'agrégation)

1. Ajoutez le Aggregate node (nœud d'agrégation) au diagramme de tâches.
2. Dans l'onglet Node properties (Propriétés de nœud), choisissez les champs à regrouper en sélectionnant le champ déroulant (facultatif). Vous pouvez sélectionner plusieurs champs à la fois ou rechercher un nom de champ en saisissant dans la barre de recherche.


Lorsque les champs sont sélectionnés, le nom et le type de données sont affichés. Pour supprimer un champ, choisissez « X » sur le champ.

Node properties
Transform **1**
Output schema

Data preview

▼ Aggregate [Info](#)

This transform first groups your rows by fields you choose, and then computes the aggregated value for fields you choose by specific function (e.g., sum, average, max).



Fields to group by - *optional*

Select the fields you would like to group your rows by, so the aggregation would be done for each unique group.

Choose one or more fields ▼

Aggregate another column

 Add an aggregation.

3. Choisissez Aggregate another column (Agréger une autre colonne). Il est nécessaire de sélectionner au moins un champ.

Field to aggregate

Choose a field ▼

Aggregation function [Info](#)

Choose a function ▼



Aggregate another column

4. Choisissez un champ dans le champ déroulant Field to aggregate (Champ à agréger).

5. Choisissez la fonction d'agrégation à appliquer au champ choisi :

- avg – calcule la moyenne
- countDistinct – calcule le nombre de valeurs uniques non null
- count – calcule le nombre de valeurs non null
- first – renvoie la première valeur qui répond aux critères de « groupe par »
- last – renvoie la dernière valeur qui répond aux critères de « groupe par »
- kurtosis – calcule la netteté du pic d'une courbe de distribution de fréquences
- max – renvoie la valeur la plus élevée qui répond aux critères de « groupe par »
- min – renvoie la valeur la plus basse qui répond aux critères de « groupe par »
- asymétrie – mesure de l'asymétrie de la distribution de probabilité d'une distribution normale
- stddev_pop – calcule l'écart type de population et renvoie la racine carrée de la variance de la population
- sum – la somme de toutes les valeurs dans le groupe
- sumDistinct – la somme des valeurs distinctes dans le groupe
- var_samp – la variance d'échantillon du groupe (ignore les valeurs nulles)
- var_pop – la variance de la population du groupe (ignore les valeurs nulles)

Aplatissement de structs imbriqués


Aplatissez les champs des structs imbriqués dans les données afin qu'ils deviennent des champs de niveau supérieur. Les nouveaux champs sont nommés en utilisant le nom du champ préfixé par les noms des champs de struct pour y accéder, séparés par des points.

Par exemple, si les données contiennent un champ de type Struct nommé « phone_numbers », celui-ci contient, entre autres, un champ de type « Struct » nommé « home_phone » avec deux champs : « country_code » et « number ». Une fois aplatis, ces deux champs deviendront des champs de niveau supérieur nommés respectivement : « phone_numbers.home_phone.country_code » et « phone_numbers.home_phone.number ».

Ajouter un nœud de transformation Aplatir à votre diagramme de tâche

1. Ouvrez le panneau Ressources, puis choisissez l'onglet Transformer, puis Aplatir pour ajouter une nouvelle transformation à votre diagramme de tâches. Vous pouvez également utiliser la

barre de recherche en saisissant « Aplatir », puis en cliquant sur le nœud Aplatir. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.



2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. (Facultatif) Dans l'onglet Transformation, vous pouvez limiter le niveau d'imbrication maximal à aplatir. Par exemple, définir cette valeur sur 1 signifie que seuls les structs de niveau supérieur seront aplatir. Le réglage de la valeur maximale sur 2 aplatira le niveau supérieur et les structs situés directement en dessous.

Ajouter une colonne UUID

Lorsque vous ajoutez une colonne UUID (identifiant unique universel), une chaîne unique de 36 caractères est attribuée à chaque ligne.

Pour ajouter un nœud de transformation UUID à votre diagramme de tâche

1. Ouvrez le panneau Ressources, puis choisissez UUID pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. (Facultatif) Dans l'onglet Transformation, vous pouvez personnaliser le nom de la nouvelle colonne. Par défaut, son nom sera « uuid ».

Ajouter une colonne d'identifiant

Attribuez un identifiant numérique à chaque ligne du jeu de données.

Ajouter un nœud de transformation d'identifiant à votre diagramme de tâches

1. Ouvrez le panneau Ressources, puis choisissez Identifiant pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. (Facultatif) Dans l'onglet Transformation, vous pouvez personnaliser le nom de la nouvelle colonne. Par défaut, son nom sera « id ».
4. (Facultatif) Si la tâche traite et stocke les données de manière incrémentielle, vous devez éviter de réutiliser les mêmes ID entre les exécutions de tâches.

Dans l'onglet Transformation, cochez la case unique. Cela inclura l'horodatage de la tâche dans l'identifiant, le rendant ainsi unique entre plusieurs exécutions. Pour tenir compte d'un nombre plus élevé, la colonne sera décimale plutôt que de type LONG.

Convertir une colonne en type d'horodatage

Vous pouvez utiliser la transformation En horodatage pour modifier le type de données d'une colonne numérique ou de chaîne en horodatage, afin qu'elle puisse être stockée avec ce type de données ou appliquée à d'autres transformations nécessitant un horodatage.

Ajouter un nœud de transformation En horodatage à votre diagramme de tâches

1. Ouvrez le panneau Ressources, puis choisissez En horodatage pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Dans l'onglet Transformation, saisissez le nom de la colonne à convertir.
4. Dans l'onglet Transformation, définissez le mode d'analyse de la colonne sélectionnée en choisissant le type.

Si la valeur est un nombre, elle peut être exprimée en secondes (horodatage Unix/Python), en millisecondes ou en microsecondes. Choisissez l'option correspondante.

Si la valeur est une chaîne formatée, choisissez le type « iso ». La chaîne doit être conforme à l'une des variantes du format ISO, par exemple : « 2022-11-02T14:40:59.915Z ».

Si vous ne connaissez pas le type à ce stade, ou si différentes lignes utilisent des types différents, vous pouvez choisir « détection automatique » et le système fera sa meilleure estimation, avec un faible coût en termes de performances.

5. (Facultatif) Dans l'onglet Transformation, au lieu de convertir la colonne sélectionnée, vous pouvez en créer une nouvelle et conserver l'originale en saisissant un nom pour la nouvelle.

Convertir une colonne d'horodatage en chaîne formatée

Formatez une colonne d'horodatage en chaîne basée sur un modèle. Vous pouvez utiliser Formater l'horodatage pour obtenir la date et l'heure sous forme de chaîne au format souhaité. Vous pouvez définir le format à l'aide de la [syntaxe de date Spark](#) ainsi que de la plupart des [codes de date Python](#).

Par exemple, si vous souhaitez que votre chaîne de date soit formatée comme « 2023-01-01 00:00 », vous pouvez définir ce format en utilisant la syntaxe Spark « yyyy-MM-dd HH:mm » ou les codes de date Python équivalents tels que « %Y-%m-%d %H : %M »

Ajouter un nœud de transformation Formater l'horodatage à votre diagramme de tâches

1. Ouvrez le panneau Ressources, puis choisissez Formater l'horodatage pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Dans l'onglet Transformation, saisissez le nom de la colonne à convertir.
4. Dans l'onglet Transformation, saisissez le modèle de Format d'horodatage à utiliser, exprimé à l'aide de la [syntaxe de date Spark](#) ou de [codes de date Python](#).
5. (Facultatif) Dans l'onglet Transformation, au lieu de convertir la colonne sélectionnée, vous pouvez en créer une nouvelle et conserver l'originale en saisissant un nom pour la nouvelle.


Création d'une transformation du routeur conditionnel

La transformation du routeur conditionnel vous permet d'appliquer plusieurs conditions aux données entrantes. Chaque ligne des données entrantes est évaluée par une condition de filtre de groupe et traitée dans le groupe correspondant. Si une ligne répond à plusieurs conditions de filtre de groupe, la transformation transmet la ligne à plusieurs groupes. Si une ligne ne répond à aucune condition, elle peut être supprimée ou acheminée vers un groupe de sortie par défaut.

Cette transformation est similaire à la transformation par filtre, mais elle est utile pour les utilisateurs qui souhaitent tester les mêmes données d'entrée sous plusieurs conditions.

Pour ajouter une transformation de routeur conditionnel :

1. Choisissez un nœud sur lequel vous allez effectuer la transformation du routeur conditionnel. Il peut s'agir d'un nœud source ou d'une autre transformation.
2. Choisissez Action, puis utilisez la barre de recherche pour rechercher et choisir « Routeur conditionnel ». Une transformation de Routeur conditionnel est ajoutée avec deux nœuds de sortie. Un nœud de sortie, « Groupe par défaut », contient des enregistrements qui ne répondent à aucune des conditions définies dans les autres nœuds de sortie. Le groupe par défaut ne peut pas être modifié.



Vous pouvez ajouter des groupes de sortie supplémentaires en choisissant Ajouter un groupe. Pour chaque groupe de sortie, vous pouvez nommer le groupe et ajouter des conditions de filtre et un opérateur logique.

Node properties **Transform** **Output schema** **Data preview**

Add group

output_group_1 **Remove group**

Define a set of conditions a record has to meet in order to be routed to the output group.

Group name
The name of this output group, as it would appear in your job. Letters, numbers, _ and - are allowed.

output_group_1

Logical operator

☒ **AND**
Trigger only when ALL conditions are met.

☐ **OR**
Trigger when at least one of the conditions is met.

Filter condition [Info](#)

Specify your filter condition by choosing the key, operator, and entering a value.

Start by adding a filter condition.

Add condition

Default group

Records which do not meet any of the conditions defined above will be routed here.

3. Renommez le nom du groupe de sortie en saisissant un nouveau nom pour le groupe. AWS Glue Studio nommera automatiquement vos groupes pour vous (par exemple, « output_group_1 »).
4. Choisissez un opérateur logique (ET, OU) et ajoutez une Condition de filtre en spécifiant la Clé, l'Opération et la Valeur. Les opérateurs logiques vous permettent d'implémenter plusieurs conditions de filtre et d'exécuter l'opérateur logique sur chaque condition de filtre que vous spécifiez.

Lorsque vous spécifiez la clé, vous pouvez choisir parmi les clés disponibles dans votre schéma. Vous pouvez ensuite choisir l'opération disponible en fonction du type de clé que vous avez sélectionné. Par exemple, si le type de clé est « chaîne », l'opération disponible à choisir est « correspondances ».

Filter condition [Info](#)

Specify your filter condition by choosing the key, operator, and entering a value.

Key

year ▼

Operation

= ▼

Value

2023

**Add condition**

5. Dans le champ Valeur, saisissez la valeur. Choisissez Ajouter une condition pour ajouter des conditions de filtre supplémentaires. Pour supprimer les conditions de filtre, sélectionnez l'icône corbeille.

Utilisation de la transformation Concaténer des colonnes pour ajouter des colonnes

La transformation Concaténer vous permet de créer une nouvelle colonne de chaîne en utilisant les valeurs d'autres colonnes avec un espacement facultatif. Par exemple, si nous définissons une colonne concaténée « date » comme la concaténation de « année », « mois » et « jour » (dans cet ordre) avec « - » comme espacement, nous obtiendrions :

day	month	year	date
01	01	2020	01/01/2020
02	01	2020	02/01/2020
03	01	2020	03/01/2020
04	01	2020	04/01/2020

Pour ajouter une transformation Concaténer :

1. Ouvrez le panneau Ressources. Choisissez ensuite Concaténer des colonnes pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.

2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Dans l'onglet Transformer, saisissez le nom de la colonne qui contiendra la chaîne concaténée ainsi que les colonnes à concaténer. L'ordre dans lequel vous cochez les colonnes de la liste déroulante sera l'ordre utilisé.

Node properties	Transform	Output schema	Data preview	
Name of the concatenated column Name of the string column that will be generated				
List of column named separated by comma or spaces The fields listed will be concatenated on that order				
Array new column Name - optional String to place between the concatenated fields, by default there is no spacer.				
Null value - optional The string to use when a column value is null, for example: 'NULL' or 'NA', by default an empty string will be used				

4. Espaceur (facultatif) : saisissez une chaîne à placer entre les champs concaténés. Par défaut, il n'y a pas d'espacement.
5. Valeur nulle (facultatif) : saisissez une chaîne à utiliser lorsqu'une valeur de colonne est nulle. Par défaut, dans les cas où les colonnes ont la valeur « NULL » ou « NA », une chaîne vide est utilisée.

Utilisation de la transformation Fractionner la chaîne pour diviser une colonne de chaînes

La transformation Fractionner la chaîne vous permet de diviser une chaîne en un tableau de jetons à l'aide d'une expression régulière pour définir la manière dont la division est effectuée. Vous pouvez

alors conserver la colonne sous forme de tableau ou appliquer une transformation Tableau vers colonnes après celle-ci, pour extraire les valeurs du tableau dans les champs de niveau supérieur, en supposant que chaque jeton a une signification que nous connaissons à l'avance. De plus, si l'ordre des jetons n'est pas pertinent (par exemple, un ensemble de catégories), vous pouvez utiliser la transformation Exploder pour générer une ligne distincte pour chaque valeur.

Par exemple, vous pouvez diviser la colonne « catégories » en utilisant une virgule comme modèle pour ajouter une colonne « categories_arr ».

product_id	categories	categories_arr
1	sports,hiver	[sports, hiver]
2	jardin,outils	[jardin, outils]
3	jeux vidéo	[jeux vidéo]
4	jeu,jeu de plateau,social	[jeu, jeu de plateau, social]

Pour ajouter une transformation Fractionner la chaîne :

1. Ouvrez le panneau Ressources, puis choisissez Fractionner la chaîne pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Dans l'onglet Transformer, choisissez la colonne à fractionner et saisissez le modèle à utiliser pour fractionner la chaîne. Dans la plupart des cas, vous pouvez simplement saisir le ou les caractères, sauf s'ils ont une signification particulière en tant qu'expression régulière et doivent être échappés. Les caractères qui doivent être échappés sont les suivants : \ . [] { } () < > * + - = ! ? ^ \$ | en ajoutant une barre oblique inverse devant le caractère. Par exemple, si vous souhaitez séparer par un point (« . »), vous devez saisir \. . Cependant, une virgule n'a pas de signification particulière et peut simplement être spécifiée telle quelle : , .

Node properties

Transform

Output schema

Data preview

Column to split

Column whose string will be split into an string array

Splitting regular expression

Regex defining the separator token, examples: ',', '\|' (pipe needs to be escaped) or '\s+' (whitespace split)

Array column Name - optional

Name to use for the column with the extracted array resulting of the split. If not specified, instead of a new column the existing one is replaced

4. (Facultatif) Si vous souhaitez conserver la colonne de chaîne d'origine, vous pouvez saisir un nom pour une nouvelle colonne de tableau, en conservant ainsi à la fois la colonne de chaîne d'origine et la nouvelle colonne de tableau tokenisée.

Utilisation de la transformation Tableau vers colonnes pour extraire les éléments d'un tableau en colonnes de niveau supérieur

La transformation Tableau vers colonnes permet d'extraire certains ou tous les éléments d'une colonne de type tableau dans de nouvelles colonnes. La transformation remplira les nouvelles colonnes autant que possible si le tableau contient suffisamment de valeurs à extraire, en prenant éventuellement les éléments aux positions spécifiées.

Par exemple, si vous avez une colonne de tableau « sous-réseau », qui est le résultat de la transformation « Diviser la chaîne » sur un sous-réseau IP v4, vous pouvez extraire les première et quatrième positions dans les nouvelles colonnes « first_octect » et « forth_octect ». Le résultat de la transformation dans cet exemple serait (remarquez que les deux dernières lignes ont des tableaux plus courts que prévu) :

sous-réseau	first_octect	fourth_octect
[54, 240, 197, 238]	54	238

sous-réseau	first_octect	fourth_octect
[192, 168, 0, 1]	192	1
[192, 168]	192	
[]		

Pour ajouter une transformation Tableau vers colonnes :

1. Ouvrez le panneau Ressources, puis choisissez Tableau vers colonnes pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Dans l'onglet Transformer, choisissez la colonne du tableau à extraire et saisissez la liste des nouvelles colonnes pour les jetons extraits.

Node properties
Transform
Output schema
Data preview

Array type column

Column of type array from which the new columns are extracted

Output columns

The names (separated by commas) of the columns to create out of the array fields. The data type will be the same as the array. For each row, the transform will try to fill them as much as possible using the array elements, the rest will be NULL

Array indexes to use - optional

List of array positions (starting from 1 and separated by commas), indicating which columns to take to fill the columns. Only need to set this if you want to skip some positions of the array

4. (Facultatif) Si vous ne voulez pas prendre les jetons du tableau pour les attribuer aux colonnes, vous pouvez spécifier les index à prendre qui seront attribués à la liste des colonnes dans le même ordre que celui indiqué. Par exemple, si les colonnes de sortie sont « colonne1, colonne2, colonne3 » et les index « 4, 1, 3 », le quatrième élément du tableau ira à la colonne1, le premier à la colonne2 et le troisième à la colonne3 (si le tableau est plus court que le nom d'index, une valeur NULL sera définie).

Utilisation de la transformation Ajouter un horodatage actuel

La transformation Ajouter un horodatage actuel vous permet de marquer les lignes avec l'heure à laquelle les données ont été traitées. Ceci est utile à des fins d'audit ou pour suivre la latence dans le pipeline de données. Vous pouvez ajouter cette nouvelle colonne sous forme de type de données d'horodatage ou de chaîne formatée.

Pour ajouter une transformation Ajouter un horodatage actuel :

1. Ouvrez le panneau Ressources, puis choisissez Ajouter un horodatage actuel pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.

Node properties	Transform	Output schema	Data preview
Timestamp column - optional Name to use for the new column, by default: timestamp. With type "string" if a dataFormat is specified, otherwise "timestamp"			
Timestamp format - optional Optional pattern to format as a string, accepts most Python date format codes, such as '%Y-%m-%d %H:%M:%S'; as well as Spark patterns such as 'yyyy-MM-dd'T'HH:mm:ss.SSSZ'			

3. (Facultatif) Dans l'onglet Transformer, saisissez un nom personnalisé pour la nouvelle colonne et un format si vous préférez que la colonne soit une chaîne de date formatée.

Utilisation de la transformation Pivoter les lignes en colonnes

La transformation Pivoter les lignes en colonnes vous permet d'agréger une colonne numérique en faisant pivoter des valeurs uniques sur des colonnes sélectionnées qui deviennent de nouvelles colonnes (si plusieurs colonnes sont sélectionnées, les valeurs sont concaténées pour nommer les nouvelles colonnes). De cette façon, les lignes sont consolidées tout en ayant davantage de colonnes avec des agrégations partielles pour chaque valeur unique. Par exemple, si vous disposez de ce jeu de données de ventes par mois et par pays (trié pour faciliter l'illustration) :

year	month	country	amount
2020	Jan	uk	32
2020	Jan	de	42
2020	Jan	us	64
2020	Fév	uk	67
2020	Fév	de	4
2020	Fév	de	7
2020	Fév	us	6
2020	Fév	us	12
2020	Jan	us	90

Si vous faites pivoter le montant et le pays comme colonnes d'agrégation, de nouvelles colonnes sont créées à partir de la colonne du pays d'origine. Dans le tableau ci-dessous, vous avez de nouvelles colonnes pour de, uk et us au lieu de la colonne country.

year	month	de	uk	us
2020	Jan	42	32	64
2020	Jan	11	67	18

year	month	de	uk	us
2021	Jan			90

Si vous souhaitez plutôt faire pivoter à la fois le mois et le pays, vous obtenez une colonne pour chaque combinaison des valeurs de ces colonnes :

year	Jan_de	Jan_uk	Jan_us	Feb_de	Feb_uk	Feb_us
2020	42	32	64	11	67	18
2021			90			

Pour ajouter une transformation Pivoter les lignes en colonnes :

1. Ouvrez le panneau Ressources, puis choisissez Pivoter les lignes en colonnes pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Dans l'onglet Transformer, choisissez la colonne numérique qui sera agrégée pour produire les valeurs des nouvelles colonnes, la fonction d'agrégation à appliquer et la ou les colonnes pour convertir leurs valeurs uniques en nouvelles colonnes.

Node properties

Transform

Output schema

Data preview

Aggregation column
Numeric column on which the aggregation function is applied

Aggregation
The Spark function to apply to the aggregation column.

Columns to convert
List of columns whose values will become new columns. If multiple columns are specified, the values are concatenated using underscore.

Choose options

Utilisation de la transformation Dépivoter les colonnes en lignes

La transformation Dépivoter vous permet de convertir des colonnes en valeurs de nouvelles colonnes en générant une ligne pour chaque valeur unique. C'est l'inverse du pivot, mais notez qu'il n'est pas équivalent puisqu'il ne peut pas séparer les lignes contenant des valeurs identiques qui ont été agrégées ou fractionnées en combinaisons dans les colonnes d'origine (vous pouvez le faire ultérieurement à l'aide d'une transformation Fractionner). Par exemple, si vous avez la table suivante :

year	month	de	uk	us
2020	Jan	42	32	64
2020	Fév	11	67	18
2021	Jan			90

Vous pouvez dépivoter les colonnes « de », « uk » et « us » dans une colonne « country » avec la valeur « amount », et obtenir ce qui suit (trié ici à des fins d'illustration) :

year	month	country	amount
2020	Jan	uk	32
2020	Jan	de	42
2020	Jan	us	64
2020	Fév	uk	67
2020	Fév	de	11
2020	Fév	us	18
2021	Jan	us	90

Notez que les colonnes qui ont une valeur NULL (« de » et « uk » de janvier 2021) ne sont pas générées par défaut. Vous pouvez activer cette option pour obtenir :

year	month	country	amount
2020	Jan	uk	32
2020	Jan	de	42
2020	Jan	us	64
2020	Fév	uk	67
2020	Fév	de	11
2020	Fév	us	18
2021	Jan	us	90
2021	Jan	de	
2021	Jan	uk	

Pour ajouter une transformation Dépivoter les colonnes en lignes :

1. Ouvrez le panneau Ressources, puis choisissez Dépivoter les colonnes en lignes pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Dans l'onglet Transformer, saisissez les nouvelles colonnes à créer pour contenir les noms et les valeurs des colonnes choisies pour être dépivotées.

Node properties	Transform	Output schema	Data preview
Unpivot names column Column to create out of the source columns names Unpivot values column Column to create out of values of the old columns Columns to unpivot into the new value column List of columns whose name will become values of the new column Choose options ▼			

Utilisation de la transformation Traitement de l'équilibre automatique pour optimiser votre exécution

La transformation Traitement de l'équilibre automatique redistribue les données entre les travailleurs pour de meilleures performances. Cela est utile dans les cas où les données sont déséquilibrées ou lorsque la source ne permet pas un traitement parallèle suffisant. Cette situation est fréquente lorsque la source est compressée ou qu'il s'agit de JDBC. La redistribution des données a un coût de performance modeste, de sorte que l'optimisation ne compense pas toujours cet effort si les données étaient déjà correctement équilibrées. Ci-dessous, la transformation utilise la répartition Apache Spark pour réaffecter les données de manière aléatoire entre un certain nombre de partitions

optimales pour la capacité du cluster. Pour les utilisateurs avancés, il est possible de saisir un certain nombre de partitions manuellement. En outre, il peut être utilisé pour optimiser l'écriture des tables partitionnées en réorganisant les données en fonction des colonnes spécifiées. Cela permet d'obtenir des fichiers de sortie plus consolidés.

1. Ouvrez le panneau Ressources, puis choisissez Traitement de l'équilibre automatique pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. (Facultatif) Dans l'onglet Transformer, vous pouvez saisir un certain nombre de partitions. En général, il est recommandé de laisser le système décider de cette valeur, mais vous pouvez ajuster le multiplicateur ou saisir une valeur spécifique si vous avez besoin de la contrôler. Si vous souhaitez enregistrer les données partitionnées par colonnes, vous pouvez choisir les mêmes colonnes comme colonnes de répartition. De cette manière, le nombre de fichiers sur chaque partition sera minimisé et il n'y aura pas beaucoup de fichiers par partition, ce qui entraverait les performances des outils qui interrogent ces données.

Node properties	Transform	Output schema	Data preview	
Number of partitions - optional Number of partitions on which to randomly distribute the data. If the number ends with the x letter then it means it's a multiple of the number of cores in the cluster. By default: 2x				
Repartition columns - optional Instead of randomly reassign the data to partitions, assign data with the same values of the columns specified to the same partition. Choose options ▼				

Utilisation de la transformation Colonnes dérivées pour combiner d'autres colonnes

La transformation Colonnes dérivées vous permet de définir une nouvelle colonne basée sur une formule mathématique ou une expression SQL dans laquelle vous pouvez utiliser d'autres colonnes

dans les données, ainsi que des constantes et des littéraux. Par exemple, pour dériver une colonne « **percentage** » à partir des colonnes « **success** » et « **count** », vous pouvez saisir l'expression SQL : « **success * 100 / count || '%'** ».

Exemple de résultat :

success	count	percentage
14	100	14 %
6	20	3 %
3	40	7,5 %

Pour ajouter une transformation Colonnes dérivées :

1. Ouvrez le panneau Ressources, puis choisissez Colonnes dérivées pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Dans l'onglet Transformer, saisissez le nom de la colonne et l'expression de son contenu.

Node properties	Transform	Output schema	Data preview	
-----------------	------------------	---------------	--------------	---

Name of the derived column

Name to use for the new column or replace an existing one

SQL Expression

A SQL expression that defines the column, which can be derived from other existing columns and use operators to modify or combine them. For instance, to derive a percentage from the columns "success" and "count", you can enter: "success * 100 / count"

Utilisation de la transformation Rechercher pour ajouter des données correspondantes à partir d'une table de catalogue

La transformation Rechercher vous permet d'ajouter des colonnes à partir d'une table de catalogue définie lorsque les clés correspondent aux colonnes de recherche définies dans les données. Cela revient à effectuer une jointure externe gauche entre les données et la table de recherche en utilisant comme condition les colonnes correspondantes.

Pour ajouter une transformation Rechercher :

1. Ouvrez le panneau Ressources, puis choisissez Rechercher pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Dans l'onglet Transformer, saisissez le nom de la table de catalogue entièrement qualifiée à utiliser pour effectuer les recherches. Par exemple, si votre base de données est « mydb » et votre table « mytable », saisissez « mydb.mytable ». Saisissez ensuite les critères permettant de trouver une correspondance dans la table de recherche, si la clé de recherche est composée. Saisissez la liste des colonnes clés séparées par des virgules. Si une ou plusieurs colonnes clés ne portent pas le même nom, vous devez définir le mappage des correspondances.

Par exemple, si les colonnes de données sont « user_id » et « region » et que dans le tableau des utilisateurs les colonnes correspondantes sont nommées « id » et « region », alors dans le champ Colonne à faire correspondre, saisissez : « user_id=id, region ». Vous pouvez saisir region=region mais ce n'est pas nécessaire, car ce sont les mêmes.

4. Enfin, saisissez les colonnes à extraire de la ligne correspondant à la table de recherche afin de les intégrer aux données. Si aucune correspondance n'est trouvée, ces colonnes seront définies sur NULL.

Note

Sous la transformation Rechercher, elle utilise une jointure gauche pour être efficace. Si la table de recherche possède une clé composite, assurez-vous que les colonnes à associer sont configurées pour correspondre à toutes les colonnes clés afin qu'il n'y ait qu'une seule correspondance possible. Sinon, plusieurs lignes de recherche

correspondent, ce qui entraîne l'ajout de lignes supplémentaires pour chacune de ces correspondances.

Node properties**Transform****Output schema****Data preview****AWS Glue Data Catalog table**

Qualified name of the catalog table to use for the lookup, specifying the database and table name separated by a dot

Lookup key columns to match

Columns in the lookup table to match separated by commas; if the column names don't match, you can specify the mapping between the data and the lookup table separating the names with an equals sign =

Lookup columns to take

Columns in the lookup table to add to the data when a match is found in the lookup table

Utilisation de la transformation Éclater le tableau ou la carte en lignes

La transformation Éclater vous permet d'extraire les valeurs d'une structure imbriquée en lignes individuelles plus faciles à manipuler. Dans le cas d'un tableau, la transformation génère une ligne pour chaque valeur du tableau, répliquant les valeurs des autres colonnes de la ligne. Dans le cas d'une carte, la transformation génère une ligne pour chaque entrée, avec la clé et la valeur comme colonnes, ainsi que toutes les autres colonnes de la ligne.

Par exemple, si nous avons ce jeu de données qui possède une colonne de type « category » contenant plusieurs valeurs.

product_id	category
1	[sports, hiver]
2	[jardin, outils]

product_id	category
3	[jeux vidéo]
4	[jeu, jeu de plateau, social]
5	[]

Si vous explodez la colonne « category » en une colonne portant le même nom, vous remplacerez la colonne. Vous pouvez sélectionner ce que vous souhaitez NULLs inclure pour obtenir les éléments suivants (commandés à des fins d'illustration) :

product_id	category
1	sports
1	hiver
2	jardin
2	outil
3	jeux vidéo
4	game
4	jeu de plateau
4	social
5	

Pour ajouter une transformation Éclater le tableau ou la carte en lignes :

1. Ouvrez le panneau Ressources, puis choisissez Éclater le tableau ou la carte en lignes pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.

2. (Facultatif) Dans l'onglet Propriétés de nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Dans l'onglet Transformer, choisissez la colonne à éclater (il doit s'agir d'un tableau ou d'un type de carte). Saisissez ensuite un nom pour la colonne des éléments du tableau ou les noms des colonnes des clés et des valeurs si vous éclatez une carte.
4. (Facultatif) Dans l'onglet Transformer, par défaut, si la colonne à éclater est NULL ou possède une structure vide, elle sera omise dans le jeu de données éclaté. Si vous souhaitez conserver la ligne (avec les nouvelles colonnes nulles), cochez « Inclure NULLs ».

Node properties	Transform	Output schema	Data preview	
Column to explode A column of type array or map 				
New column name The name of the column to put the array values or the dictionary keys 				
Values column - optional If exploding a dictionary, you can specify a name for a column to contain the values. Default name: "value" 				
Include NULLs - optional If selected, NULL values will also generate a new rows, otherwise the row with a NULL value is omitted ☐				

Utilisation de la transformation Correspondance des enregistrements pour invoquer une transformation de classification de données existante

Cette transformation invoque une transformation existante de classification de données de machine learning Correspondance des enregistrements.

La transformation évalue les données actuelles par rapport au modèle entraîné sur la base des étiquettes. Une colonne « match_id » est ajoutée pour attribuer chaque ligne à un groupe

d'éléments considérés comme équivalents sur la base de l'apprentissage de l'algorithme. Pour plus d'informations, voir [Correspondance des enregistrements avec Lake Formation FindMatches](#).

Note

La version AWS Glue utilisée par la tâche visuelle doit correspondre à la version AWS Glue utilisée pour créer la transformation Record Matching.

Transform

Output schema

Data preview

Data preview (20)

Info

Previewing 6 of 7 fields

Filter sample dataset

id	title	venue	year	source	match_id
journals_sigmod_Liu02	Editor's Notes	SIGMOD Record	2002	DBLP	25769803776
journals_sigmod_Hammer02	Report on the ACM Fourth International Workshop on Data Warehousing and OLAP (DOLAP 2001)	null	2002	DBLP	25769803777
journals_sigmod_Konig-RiesMMPPRSVW02	Report on the NSF Workshop on Building an Infrastructure for Mobile and Wireless Systems	null	2002	DBLP	68719476736

Pour ajouter un nœud de transformation Correspondance des enregistrements à votre diagramme de tâche

1. Ouvrez le panneau Ressources, puis choisissez Correspondance des enregistrements pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. Dans le panneau des propriétés du nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste de Node parents (Parents de nœud) à utiliser comme source pour la transformation.

3. Dans l'onglet Transformer, saisissez l'ID extrait de la page des Transformations du machine learning :

AWS Glue > ML transforms

Machine learning transforms (1) [Info](#)
Clean all your data using machine learning transforms.

	Transform name ▲	ID	Status ▼	Label count ▼
☐	Test	tfm-3d291b652cec092a79aeda5062f2c96e7c528474	✓ Ready for use	352

4. (Facultatif) Dans l'onglet Transformer, vous pouvez cocher l'option permettant d'ajouter les scores de confiance. Au prix d'un calcul supplémentaire, le modèle estimera un score de confiance pour chaque correspondance dans une colonne supplémentaire.

Supprimer les lignes nulles

Cette transformation supprime du jeu de données les lignes dont toutes les colonnes sont nulles. En outre, vous pouvez étendre ce critère pour inclure les champs vides, afin de conserver les lignes dont au moins une colonne n'est pas vide.

Pour ajouter un nœud de transformation Supprimer les lignes nulles à votre diagramme de tâche

1. Ouvrez le panneau Ressources, puis choisissez Supprimer les lignes nulles pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. Dans le panneau des propriétés du nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste de Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. (Facultatif) Dans l'onglet Transformer, cochez l'option Étendu si vous souhaitez que les lignes ne soient pas simplement nulles, mais également qu'elles ne soient pas vides. Ainsi, les chaînes, les tableaux ou les cartes vides seront considérés comme nuls dans le cadre de cette transformation.

Analyse d'une colonne de chaîne contenant des données JSON

Cette transformation analyse une colonne de chaîne contenant des données JSON et la convertit en une structure ou en une colonne de tableau, selon que le JSON est respectivement un objet ou un tableau. Vous pouvez éventuellement conserver la colonne analysée et la colonne d'origine.

Le schéma JSON peut être fourni ou déduit (dans le cas des objets JSON), avec un échantillonnage facultatif.

Pour ajouter un nœud de transformation Analyser la colonne JSON à votre diagramme de tâches

1. Ouvrez le panneau Ressources, puis choisissez Analyser la colonne JSON pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. Dans le panneau des propriétés du nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste de Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Dans l'onglet Transformer, sélectionnez la colonne contenant la chaîne JSON.
4. (Facultatif) Dans l'onglet Transformer, saisissez le schéma suivi par les données JSON en utilisant la syntaxe SQL, par exemple : « field1 STRING, field2 INT » dans le cas d'un objet ou « ARRAY<STRING> » dans le cas d'un tableau.

Dans le cas d'un tableau, le schéma est obligatoire, mais dans le cas d'un objet, si le schéma n'est pas spécifié, il sera déduit à l'aide des données. Pour réduire l'impact de l'inférence du schéma (en particulier sur un jeu de données volumineux), vous pouvez éviter de lire le jeu de données deux fois en saisissant un Ratio d'échantillons à utiliser pour déduire le schéma. Si la valeur est inférieure à 1, le ratio correspondant d'échantillons aléatoires est utilisé pour déduire le schéma. Si les données sont fiables et que l'objet est cohérent entre les lignes, vous pouvez utiliser un faible ratio tel que 0,1 pour améliorer les performances.

5. (Facultatif) Dans l'onglet Transformer, vous pouvez saisir un nouveau nom de colonne si vous souhaitez conserver à la fois la colonne de chaîne d'origine et la colonne analysée.

Extraction d'un chemin JSON

Cette transformation extrait les nouvelles colonnes d'une colonne de chaîne JSON. Cette transformation est utile lorsque vous n'avez besoin que de quelques éléments de données et que vous ne souhaitez pas importer l'intégralité du contenu JSON dans le schéma de la table.

Pour ajouter un nœud de transformation Extraire un chemin JSON à votre diagramme de tâches

1. Ouvrez le panneau Ressources, puis choisissez Extraire un chemin JSON pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. Dans le panneau des propriétés du nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste de Node parents (Parents de nœud) à utiliser comme source pour la transformation.
3. Dans l'onglet Transformer, sélectionnez la colonne contenant la chaîne JSON. Saisissez une ou plusieurs expressions de chemin JSON séparées par des virgules, chacune indiquant comment extraire une valeur du tableau ou de l'objet JSON. Par exemple, si la colonne JSON contient un objet avec les propriétés « prop_1 » et « prop2 », vous pouvez extraire les deux en spécifiant leurs noms « prop_1, prop_2 ».

Si le champ JSON contient des caractères spéciaux, par exemple pour extraire la propriété de ce `{ "a . a" : 1 }` JSON, vous pouvez utiliser le chemin `$[ ' a . a ' ]`. La virgule est l'exception, car elle est réservée à la séparation des chemins. Saisissez ensuite les noms de colonnes correspondants pour chaque chemin, en les séparant par des virgules.

4. (Facultatif) Dans l'onglet Transformer, vous pouvez cocher la case pour supprimer la colonne JSON une fois extraite. Cela est utile lorsque vous n'avez pas besoin du reste des données JSON une fois que vous avez extrait les parties dont vous avez besoin.

Extraction de fragments de chaîne à l'aide d'une expression régulière

Cette transformation extrait des fragments de chaîne à l'aide d'une expression régulière et crée une nouvelle colonne à partir de celle-ci, ou plusieurs colonnes si vous utilisez des groupes d'expressions régulières.

Pour ajouter un nœud de transformation Extracteur d'expressions régulières à votre diagramme de tâche

1. Ouvrez le panneau Ressources, puis choisissez Extracteur d'expressions régulières pour ajouter une nouvelle transformation à votre diagramme de tâches. Le nœud sélectionné au moment de l'ajout du nœud sera son parent.
2. Dans le panneau des propriétés du nœud, vous pouvez saisir un nom pour le nœud dans le diagramme de tâches. Si aucun parent de nœud n'est déjà sélectionné, choisissez un nœud dans la liste de Node parents (Parents de nœud) à utiliser comme source pour la transformation.

3. Dans l'onglet Transformer, saisissez l'expression régulière et la colonne sur laquelle elle doit être appliquée. Saisissez ensuite le nom de la nouvelle colonne dans laquelle vous souhaitez stocker la chaîne de caractères correspondante. La nouvelle colonne sera nulle uniquement si la colonne source est nulle, si l'expression régulière ne correspond pas, la colonne sera vide.

Si l'expression régulière utilise des groupes, il doit y avoir un nom de colonne correspondant séparé par une virgule, mais vous pouvez ignorer les groupes en laissant le nom de colonne vide.

Par exemple, si vous avez une colonne « `purchase_date` » avec une chaîne utilisant à la fois des formats de date ISO longs et courts, vous souhaitez extraire l'année, le mois, le jour et l'heure, lorsqu'ils sont disponibles. Remarquez que le groupe « heure » est facultatif, sinon dans les lignes où il n'y a pas de données disponibles, tous les groupes extraits seraient des chaînes vides (car l'expression régulière ne correspond pas). Dans ce cas, nous ne voulons pas que le groupe rende l'heure facultative, mais plutôt la partie interne. Nous laissons donc le nom vide et il ne sera pas extrait (ce groupe inclurait le caractère T).

Transform | **Output schema** | **Data preview** 

Name

Node parents
Choose which nodes will provide inputs for this one.

Choose one or more parent node ▼

S3 bucket X

S3 - DataSource

Column to extract from
String column on which to apply the regex.

purchase_date ▼
string

Regular expression
Regex to apply on the column, if multiple columns need to be extracted then the expression needs an equal number of groups.

Extracted column
The name of the column where to extract the matched regex. Multiple column names can be specified separated by commas, if the name is empty it means that group is skipped. If the source column is null, the new column will be null as well, otherwise an empty string means there was no match.

L'aperçu des données s'affiche :

Data preview (5) [Info](#)

Previewing 5 of 5 fields



purchase_date	year	month	day	hour
2023-03-04T12:23:31	2023	03	04	12
2021-06-09T02:21:01	2021	06	09	02
2022-02-04	2022	02	04	
2020-09-05T23:07:02	2020	09	05	23
2020-09-08	2020	09	08	

Créer une transformation personnalisée

Si vous avez besoin d'effectuer des transformations plus compliquées sur vos données ou si vous souhaitez ajouter des clés de propriété de données au jeu de données, vous pouvez ajouter une transformation Custom code (Code personnalisé) à votre diagramme de tâches. Le nœud de code personnalisé vous permet de saisir un script qui effectue la transformation.

Lorsque vous utilisez du code personnalisé, vous devez utiliser un éditeur de schéma pour indiquer les modifications apportées au résultat au travers du code personnalisé. Lorsque vous modifiez le schéma, vous pouvez exécuter les actions suivantes :

- Ajouter ou supprimer des clés de propriété de données
- Modifier le type de données des clés de propriété de données
- Modifier le nom des clés de propriété de données
- Restructurer une clé de propriété imbriquée

Vous devez utiliser une `SelectFromCollection` transformation pour en choisir une `DynamicFrame` parmi le résultat de votre nœud de transformation personnalisé avant de pouvoir envoyer la sortie vers un emplacement cible.

Utilisez les tâches suivantes pour ajouter un nœud de transformation personnalisé à votre diagramme de tâches.

Ajout d'un nœud de transformation de code personnalisé au diagramme de tâche

Pour ajouter un nœud de transformation personnalisé à votre diagramme de tâche

1. (Facultatif) Ouvrez le panneau Ressources, puis choisissez Transformation personnalisée pour ajouter une nouvelle transformation à votre diagramme de tâches.
2. Sur la page Node properties (Propriétés de nœud) au cours de la tâche, saisissez un nom pour le nœud dans le diagramme de tâche. Si un parent de nœud n'est pas déjà sélectionné, ou si vous souhaitez plusieurs entrées pour la transformation personnalisée, choisissez un nœud dans la liste Node parents (Parents de nœud) à utiliser comme source pour la transformation.

Saisie du code pour le nœud de transformation personnalisé

Vous pouvez taper ou copier du code dans un champ de saisie. La tâche utilise ce code pour effectuer la transformation des données. Vous pouvez fournir un extrait de code Python ou Scala. Le code doit inclure un ou plusieurs `DynamicFrames` en entrée et retourne une collection de `DynamicFrames`.

Pour saisir le script d'un nœud de transformation personnalisé

1. Lorsque le nœud de transformation personnalisé est sélectionné dans le diagramme de tâche, choisissez l'onglet Transform (Transformation).
2. Dans le champ de saisie de texte sous l'en-tête Bloc de code, collez ou saisissez le code pour la transformation. Le code que vous utilisez doit correspondre au langage spécifié pour la tâche dans l'onglet Job details (Détails de la tâche).

Lorsque vous vous référez aux nœuds d'entrée de votre code, AWS Glue Studio nomme les nœuds `DynamicFrames` renvoyés par le diagramme de tâches de manière séquentielle en fonction de l'ordre de création. Utilisez l'une des méthodes de dénomination suivantes dans votre code :

- Génération de code classique – Utilisez des noms fonctionnels pour faire référence aux nœuds de votre diagramme de tâches.
 - Nœuds de source de données : `DataSource0`, `DataSource1`, `DataSource2`, etc.
 - Transform nodes : `Transform0`, `Transform1`, `Transform2`, etc.
- Génération d'un nouveau code – Utilisez le nom spécifié dans l'onglet Node properties (Propriétés du nœud) d'un nœud, complété par « `_node1` », « `_node2` », etc.

Par exemple S3bucket_node1, ApplyMapping_node2, S3bucket_node2, MyCustomNodeName_node1.

Pour en savoir plus sur le nouveau générateur de code, consultez [Génération de code de script](#).

Les exemples suivants montrent le format du code à saisir dans la zone de code :

Python

L'exemple suivant prend le premier DynamicFrame reçu, le convertit en DataFrame pour appliquer la méthode de filtre native (ne conservant que les enregistrements qui ont plus de 1000 votes), puis la convertit en un DynamicFrame avant de le retourner.

```
def FilterHighVoteCounts (glueContext, dfc) -> DynamicFrameCollection:
    df = dfc.select(list(dfc.keys())[0]).toDF()
    df_filtered = df.filter(df["vote_count"] > 1000)
    dyf_filtered = DynamicFrame.fromDF(df_filtered, glueContext, "filter_votes")
    return(DynamicFrameCollection({"CustomTransform0": dyf_filtered}, glueContext))
```

Scala

L'exemple suivant prend le premier DynamicFrame reçu, le convertit en DataFrame pour appliquer la méthode de filtre native (ne conservant que les enregistrements qui ont plus de 1000 votes), puis la convertit en un DynamicFrame avant de le retourner.

```
object FilterHighVoteCounts {
    def execute(glueContext : GlueContext, input : Seq[DynamicFrame]) :
    Seq[DynamicFrame] = {
        val frame = input(0).toDF()
        val filtered = DynamicFrame(frame.filter(frame("vote_count") > 1000),
        glueContext)
        Seq(filtered)
    }
}
```

Modifier le schéma d'un nœud de transformation personnalisé

Lorsque vous utilisez un nœud de transformation personnalisé, AWS Glue Studio ne peut pas déduire automatiquement les schémas de sortie créés par la transformation. Vous utilisez l'éditeur

de schéma pour décrire les modifications de schéma implémentées par le code de transformation personnalisé.

Un nœud de code personnalisé peut avoir n'importe quel nombre de nœuds parents, chacun fournissant un `DynamicFrame` comme source pour votre code personnalisé. Un nœud de code personnalisé renvoie un ensemble de `DynamicFrames`. Chaque `DynamicFrame` qui est utilisé comme entrée a un schéma associé. Vous devez ajouter un schéma qui décrit chaque `DynamicFrame` retourné par le nœud de code personnalisé.

Note

Lorsque vous définissez votre propre schéma pour une transformation personnalisée, AWS Glue Studio n'hérite pas des schémas des nœuds précédents. Pour mettre à jour le schéma, sélectionnez le nœud de transformation personnalisée, puis choisissez l'onglet Aperçu des données. Une fois l'aperçu généré, choisissez « Use Preview Schema » (Utiliser le schéma d'aperçu). Le schéma sera ensuite remplacé par le schéma à l'aide de la prévisualisation des données.

Vous modifiez ici les schémas d'un nœud de transformation personnalisé

1. Lorsque le nœud de transformation personnalisé est sélectionné dans le diagramme de tâche, dans le volet de détails du nœud, choisissez l'onglet Output Schema (Schéma de sortie).
2. Choisissez Edit (Modifier) pour apporter des modifications au schéma.

Si vous avez des clés de propriété de données imbriquées, telles qu'un tableau ou un objet, vous pouvez choisir l'icône Expand-Rows (Développez les lignes)



en haut à droite de chaque volet de schéma pour développer la liste des clés de propriété de données enfant. Une fois que vous avez sélectionné cette icône, elle devient Collapse-Rows (Réduire les lignes)



que vous pouvez choisir de réduire la liste des clés de propriété enfants.

3. Modifiez le schéma à l'aide des actions suivantes, dans la section à droite de la page :

- Pour renommer une clé de propriété, placez le curseur dans la zone de texte Key (Clé) de la clé de propriété, puis saisissez le nouveau nom.

- Pour modifier le type de données d'une clé de propriété, utilisez la liste pour choisir le nouveau type de données pour la clé de propriété.
 - Pour ajouter une nouvelle colonne de niveau supérieur au schéma, choisissez l'icône Overflow (Surcharger) (...) à droite du bouton Cancel (Annuler), puis choisissez Add root key (Ajouter une clé racine).
 - Pour ajouter une clé de propriété enfant au schéma, choisissez l'icône Add-Key (Ajouter une clé) () associée à la clé parent. Saisissez un nom pour la clé enfant et choisissez le type de données.
 - Pour supprimer une clé de propriété du schéma, choisissez l'icône Remove (Supprimer) () à l'extrême droite du nom de la clé.
4. Si votre code de transformation personnalisé utilise plusieurs DynamicFrames, vous pouvez ajouter d'autres schémas de sortie.
- Pour ajouter un nouveau schéma vide, choisissez Overflow (Surcharger) (...), puis choisissez Add output schema (Ajouter un schéma de sortie).
 - Pour copier un schéma existant dans un nouveau schéma en sortie, assurez-vous que le schéma à copier est affiché dans le sélecteur de schéma. Choisissez l'icône Overflow (Surcharger) (...), puis choisissez Duplicate (Dupliquer).

Si vous souhaitez supprimer un schéma en sortie, assurez-vous que le schéma que vous souhaitez copier est affiché dans le sélecteur de schéma. Choisissez l'icône Overflow (Surcharger) (...), puis choisissez Delete (Supprimer).

5. Ajoutez de nouvelles clés racine au nouveau schéma ou modifiez les clés dupliquées.
6. Lorsque vous modifiez les schémas en sortie, choisissez le bouton Apply (Appliquer) pour sauvegarder vos modifications et quitter l'éditeur de schéma.

Si vous ne souhaitez pas enregistrer vos modifications, choisissez le bouton Cancel (Annuler).

Configurer la sortie de transformation personnalisée

Une transformation de code personnalisée renvoie une collection de `DynamicFrames`, même s'il n'y a qu'un seul `DynamicFrame` dans le jeu de résultats.

Pour traiter la sortie à partir d'un nœud de transformation personnalisé

1. Ajoutez un nœud de `SelectFromCollectiontransformation` dont le nœud de transformation personnalisé est le nœud parent. Mettez à jour cette transformation pour indiquer le jeu de données que vous souhaitez utiliser. Pour plus d'informations, consultez [Utilisation SelectFromCollection pour choisir le jeu de données à conserver](#).
2. Ajoutez des `SelectFromCollectiontransformations` supplémentaires au diagramme de tâches si vous souhaitez utiliser des transformations supplémentaires `DynamicFrames` produites par le nœud de transformation personnalisé.

Considérez un scénario dans lequel vous ajoutez un nœud de transformation personnalisé pour diviser un jeu de données de vol en plusieurs jeux de données, mais dupliquez certaines des clés de propriété d'identification dans chaque schéma en sortie, telles que la date de vol ou le numéro de vol. Vous ajoutez un nœud de `SelectFromCollectiontransformation` pour chaque schéma de sortie, le nœud de transformation personnalisé étant son parent.

3. (Facultatif) Vous pouvez ensuite utiliser chaque nœud de `SelectFromCollectiontransformation` comme entrée pour les autres nœuds de la tâche ou comme parent pour un nœud cible de données.

Transformez les données grâce à des transformations visuelles personnalisées

Les transformations visuelles personnalisées vous permettent de créer des transformations et de les rendre disponibles pour une utilisation dans AWS Glue Studio emplois. Les transformations visuelles personnalisées permettent aux développeurs ETL, qui ne sont peut-être pas familiarisés avec le codage, de rechercher et d'utiliser une bibliothèque croissante de transformations à l'aide du AWS Glue Studio l'interface.

Vous pouvez créer une transformation visuelle personnalisée, puis la télécharger sur Amazon S3 pour la rendre utilisable via l'éditeur visuel dans AWS Glue Studio pour travailler avec ces emplois.

Rubriques

- [Premiers pas avec les transformations visuelles personnalisées](#)

- [Étape 1. Créer un fichier de configuration JSON](#)
- [Étape 2. Implémenter la logique de transformation](#)
- [Étape 3. Valider et résoudre les problèmes liés aux transformations visuelles personnalisées dans AWS Glue Studio](#)
- [Étape 4 : Mettre à jour les transformations visuelles personnalisées selon les besoins](#)
- [Étape 5. Utilisez des transformations visuelles personnalisées dans AWS Glue Studio](#)
- [Exemples d'utilisation](#)
- [Exemples de scripts visuels personnalisés](#)
- [Vidéo](#)

Premiers pas avec les transformations visuelles personnalisées

Pour créer une transformation visuelle personnalisée, suivez les étapes ci-dessous.

- Étape 1. Créer un fichier de configuration JSON
- Étape 2. Implémenter la logique de transformation
- Étape 3. Valider la transformation visuelle personnalisée
- Étape 4 : Mettre à jour la transformation visuelle personnalisée selon les besoins
- Étape 5. Utilisez la transformation visuelle personnalisée dans AWS Glue Studio

Commencez par configurer le compartiment Amazon S3, puis passez à la section Étape 1. Créer un fichier de configuration JSON.

Prérequis

Les transformations fournies par le client sont enregistrées dans un compte client AWS . Ce compte est propriétaire des transformations et dispose donc de toutes les autorisations nécessaires pour les consulter (recherche et utilisation), les modifier ou les supprimer.

Pour utiliser une transformation personnalisée dans AWS Glue Studio, vous devrez créer et charger deux fichiers dans le compartiment d'actifs Amazon S3 de ce AWS compte :

- Fichier Python : contient la fonction de transformation.
- Fichier JSON : décrit la transformation. Il s'agit également du fichier de configuration requis pour définir la transformation.

Pour associer les fichiers, utilisez le même nom pour les deux. Par exemple :

- `maTransformation.json`
- `maTransformation.py`

Vous pouvez éventuellement attribuer une icône personnalisée à votre transformation visuelle personnalisée en fournissant un fichier SVG contenant l'icône. Pour associer les fichiers, utilisez le même nom pour l'icône :

- `myTransform.svg`

AWS Glue Studio les associera automatiquement à l'aide de leurs noms de fichiers respectifs. Les noms de fichiers ne peuvent pas être les mêmes pour tous les modules existants.

Convention recommandée pour le nom du fichier de transformation

AWS Glue Studio importera votre fichier en tant que module (par exemple, `import myTransform`) dans votre script de travail. Par conséquent, le nom de votre fichier doit suivre les mêmes règles de dénomination que celles définies pour les noms (identifiants) de variables Python. Plus précisément, ils doivent commencer par une lettre ou un trait de soulignement, puis être entièrement composés de lettres, de chiffres et/ou de traits de soulignement.

Note

Assurez-vous que le nom de votre fichier de transformation n'est pas en conflit avec les modules Python existants déjà chargés (par exemple, `sys`, `array`, `copy`, etc.) pour éviter tout problème d'exécution inattendu.

Configuration du compartiment Amazon S3

Les transformations que vous créez sont stockées dans Amazon S3 et appartiennent à votre AWS compte. Pour créer de nouvelles transformations visuelles personnalisées, il vous suffit de charger des fichiers (json et py) dans le dossier des ressources Amazon S3 où sont actuellement stockés tous les scripts de travail (par exemple, `s3://aws-glue-assets-<accountid>-<region>/transforms`). Si vous utilisez une icône personnalisée, chargez-la également. Par défaut, AWS Glue Studio lira tous les fichiers .json du dossier `/transform` dans le même compartiment S3.

Étape 1. Créer un fichier de configuration JSON

Vous devez disposer d'un fichier de configuration JSON pour définir et décrire votre transformation visuelle personnalisée. Le schéma du fichier de configuration est le suivant.

Structure du fichier JSON

Champs

- `name: string` (obligatoire) : nom du système de transformation utilisé pour identifier les transformations. Respecte les mêmes règles de dénomination que celles définies pour les noms (identifiants) de variables Python. Plus précisément, ils doivent commencer par une lettre ou un trait de soulignement, puis être entièrement composés de lettres, de chiffres et/ou de traits de soulignement.
- `displayName: string`— (facultatif) le nom de la transformation affichée dans AWS Glue Studio éditeur de tâches visuel. Si non `displayName` est spécifié, le `name` est utilisé comme nom de la transformation dans AWS Glue Studio.
- `description: string`— (facultatif) la description de la transformation est affichée dans AWS Glue Studio et est consultable.
- `functionName: string` (obligatoire) : nom de la fonction Python utilisé pour identifier la fonction à appeler dans le script Python.
- `path: string` (facultatif) : chemin d'accès Amazon S3 au fichier source Python. Si ce n'est pas précisé, AWS Glue utilise la correspondance des noms de fichiers pour associer les fichiers `.json` et `.py`. Par exemple, le nom du fichier JSON, `myTransform.json`, est associé au fichier Python, `myTransform.py`, au même emplacement Amazon S3.
- `parameters: Array of TransformParameter object`— (facultatif) la liste des paramètres à afficher lorsque vous les configurez dans AWS Glue Studio éditeur visuel.

TransformParameter champs

- `name: string` (obligatoire) : nom du paramètre transmis à la fonction Python en tant qu'argument nommé dans le script de travail. Respecte les mêmes règles de dénomination que celles définies pour les noms (identifiants) de variables Python. Plus précisément, ils doivent commencer par une lettre ou un trait de soulignement, puis être entièrement composés de lettres, de chiffres et/ou de traits de soulignement.

- `displayName`: `string`— (facultatif) le nom de la transformation affichée dans AWS Glue Studio éditeur de tâches visuel. Si non `displayName` est spécifié, le `name` est utilisé comme nom de la transformation dans AWS Glue Studio.
- `type`: `string` (obligatoire) : type de paramètre acceptant les types de données Python courants. Valeurs valides : `'str' | 'int' | 'float' | 'list' | 'bool'`.
- `isOptional`: `boolean` : (facultatif) détermine si le paramètre est facultatif. Par défaut, tous les paramètres sont obligatoires.
- `description`: `string`— (facultatif) la description est affichée dans AWS Glue Studio pour aider l'utilisateur à configurer le paramètre de transformation.
- `validationType`: `string` (facultatif) : définit le mode de validation de ce paramètre. Actuellement, seules les expressions régulières sont prises en charge. Par défaut, le type de validation est défini sur `RegularExpression`.
- `validationRule`: `string` (facultatif) : expression régulière utilisée pour valider les entrées du formulaire avant l'envoi, lorsque `validationType` est défini sur `RegularExpression`. La syntaxe des expressions régulières doit être compatible avec les spécifications [RegExp EcmaScript](#).
- `validationMessage`: `string` (facultatif) : message à afficher en cas d'échec de la validation.
- `listOptions`: An array of `TransformParameterListOption` object ou une `string` ou la valeur de chaîne « `column` » : (facultatif) options à afficher dans le contrôle de sélection unique ou multiple de l'interface utilisateur. Accepte une liste de valeurs séparées par des virgules ou un objet JSON de type `TransformParameterListOption`. Il peut également remplir dynamiquement la liste des colonnes à partir du schéma du nœud parent en spécifiant la valeur de chaîne « `column` ».
- `listType`: `string` (facultatif) : définit les types d'options de type `'list'`. Valeurs valides : `'str' | 'int' | 'float' | 'list' | 'bool'`. Type de paramètre acceptant les types de données Python courants.

TransformParameterListOption champs

- `value`: `string | int | float | bool` (obligatoire) : valeur de l'option.
- `label`: `string` (facultatif) : étiquette d'option affichée dans la liste déroulante de sélection.

Transformer les paramètres dans AWS Glue Studio

Par défaut, les paramètres sont obligatoires, sauf s'ils sont accompagnés de la mention `isOptional` dans le fichier `.json`. Entrée AWS Glue Studio, les paramètres sont affichés dans l'onglet

Transformation. L'exemple présente des paramètres définis par l'utilisateur, tels que Email Address (Adresse e-mail), Phone Number (Numéro de téléphone), Your age (Votre âge), Your gender (Votre sexe) et Your origin (Votre pays d'origine).

The screenshot shows the AWS Glue Studio interface. On the left, a canvas displays a data pipeline with two nodes: 'Data source - S3 bucket Amazon S3' and 'Transform - Dynamic Trans... My Transform'. A blue arrow connects the data source to the transform node. On the right, the 'Transform' node properties are visible, showing fields for 'Email Address', 'Phone Number', 'Your age', 'Your gender', and 'Your origin country? - optional'. The 'Email Address' field is a text input. The 'Phone Number' field is a text input. The 'Your age' field is a text input. The 'Your gender' field is a dropdown menu. The 'Your origin country? - optional' field is a dropdown menu with the text 'Choose options'. Below these fields, there is a checkbox for 'Do you want to receive promotional newsletter from us? - optional'.


Vous pouvez appliquer certaines validations dans AWS Glue Studio en utilisant des expressions régulières dans le fichier json en spécifiant le `validationRule` paramètre et en spécifiant un message de validation dans `validationMessage`.

```
"validationRule": "^\\((?\\d{3})\\)?[- ]?(\\d{3})[- ]?(\\d{4})$",
"validationMessage": "Please enter a valid US number"
```

Note

La validation ayant lieu dans le navigateur, la syntaxe de vos expressions régulières doit être compatible avec les spécifications [RegExp EcmaScript](#). La syntaxe Python n'est pas prise en charge pour ces expressions régulières.

L'ajout d'une validation empêchera l'utilisateur d'enregistrer le travail avec une saisie incorrecte. AWS Glue Studio affiche le message de validation tel qu'il apparaît dans l'exemple :



The screenshot shows the 'Transform' tab in AWS Glue Studio. It features a form with a label 'Email Address' and a prompt 'Enter your work email address below'. The input field contains the text 'wrongEmail.com'. Below the field, a red warning message with a triangle icon states 'Please enter a valid email address'. The top navigation bar includes 'Node properties', 'Transform' (highlighted with a red circle and the number 1), 'Output schema', and 'Data preview'.

Les paramètres sont affichés dans AWS Glue Studio en fonction de la configuration des paramètres.

- Lorsque le type correspond à `str`, `int` ou `float`, un champ de saisie de texte s'affiche. Par exemple, la capture d'écran illustre les champs de saisie des paramètres « Adresse e-mail » et « Votre âge ».

Email Address
Enter your work email address below

Your age

- Lorsque le type correspond à `bool`, une case à cocher s'affiche.

Do you want to receive promotional newsletter from us?

☐

- Lorsque le type correspond à `str` et que `listOptions` est fourni, une liste de sélection unique s'affiche.

Your gender

Male	▲
Male	✓
Female	
Other	

- Lorsque le type correspond à `list` et que `listOptions` et `listType` sont fournis, une liste de sélection multiple s'affiche.

Country recently visited - optional

What countries did you visit in the past 2 years?

Choose options ▲

Q

☐ Iceland

☒ India 

☐ Indor 

☐ Iran

☐ Iraq

☐ Ireland

☒ Israel

☐ Italy

☐ Jamaica

☐ Japan

Afficher un sélecteur de colonne en tant que paramètre

Si la configuration nécessite que l'utilisateur choisisse une colonne dans le schéma, vous pouvez afficher un sélecteur de colonne afin que l'utilisateur n'ait pas à saisir le nom de la colonne. En réglant le `listOptions` champ sur « colonne », AWS Glue Studio affiche dynamiquement un sélecteur de colonne basé sur le schéma de sortie du nœud parent. AWS Glue Studio peut afficher un sélecteur de colonne unique ou multiple.

L'exemple suivant utilise le schéma :

Node properties	Data source properties - S3	Output schema	Data preview
Schema			Edit
Key	Data type	Partition	
CustomerID	string	-	
Title	string	-	
FirstName	string	-	
LastName	string	-	
EmailAddress	string	-	
Phone	string	-	
CompanyName	string	-	

Pour définir votre paramètre de transformation visuelle personnalisée afin d'afficher une seule colonne :

1. Dans votre fichier JSON, pour l'objet `parameters`, définissez la valeur `listOptions` sur « column ». Cela permet à un utilisateur de choisir une colonne dans une liste de sélection AWS Glue Studio.

```
{
  "name": "mb_to_timestamp",
  "displayName": "MB Convert column to timestamp",
  "description": "Convert a timestamp string or a system epoch column into a new timestamp type column.",
  "functionName": "mb_to_timestamp",
  "parameters": [
    {
      "name": "columnName",
      "displayName": "Name of the column with the time",
      "type": "str",
      "listOptions": "column",
      "description": "Column with an epoch or string to be converted"
    }
  ]
}
```

Node properties

Transform

Output schema

Data preview

Name of the column with the time
Column with an epoch or string to be converted

Choose one column

CustomerID
string

Title
string

FirstName
string

LastName
string

EmailAddress
string

Phone
string

CompanyName
string

2. Vous pouvez également autoriser la sélection de plusieurs colonnes en définissant le paramètre comme suit :

- `listOptions`: "column"
- `type`: "list"

```
{
  "name": "mb_to_timestamp",
  "displayName": "MB Convert column to timestamp",
  "description": "Convert a timestamp string or a system epoch column into a new timestamp type column.",
  "functionName": "mb_to_timestamp",
  "parameters": [
    {
      "name": "colNames",
      "displayName": "Name of the column with the time",
      "type": "list",
      "listOptions": "column",
      "listType": "str",
      "description": "Column with an epoch or string to be converted"
    }
  ]
}
```

Étape 2. Implémenter la logique de transformation

Note

Les transformations visuelles personnalisées ne prennent en charge que les scripts Python. Scala n'est pas pris en charge.

Pour ajouter le code qui implémente la fonction définie par le fichier de configuration .json, il est recommandé de placer le fichier Python au même endroit que le fichier .json, avec le même nom mais avec l'extension « .py ». AWS Glue Studio associe automatiquement les fichiers .json et .py afin que vous n'ayez pas besoin de spécifier le chemin du fichier Python dans le fichier de configuration.

Dans le fichier Python, ajoutez la fonction déclarée, avec les paramètres nommés configurés, et enregistrez-la pour qu'elle soit utilisée dans `DynamicFrame`. Voici un exemple de fichier Python :

```
from awsglue import DynamicFrame

# self refers to the DynamicFrame to transform,
# the parameter names must match the ones defined in the config
# if it's optional, need to provide a default value
def myTransform(self, email, phone, age=None, gender="",
                 country="", promotion=False):
```

```
resulting_dynf = # do some transformation on self
return resulting_dynf
```

```
DynamicFrame.myTransform = myTransform
```

Il est recommandé d'utiliser un AWS Glue bloc-notes pour le moyen le plus rapide de développer et de tester le code python. Voir [Commencer à utiliser les blocs-notes dans AWS Glue Studio](#).

Pour illustrer l'implémentation de la logique de transformation, la transformation visuelle personnalisée présentée dans l'exemple ci-dessous permet de filtrer les données entrantes afin de ne conserver que les données relatives à un État américain en particulier. Le fichier .json contient le paramètre `custom_filter_state` pour `functionName` ainsi que deux arguments (« `state` » et « `colName` » avec le type « `str` »).

L'exemple de fichier de configuration .json est le suivant :

```
{
  "name": "custom_filter_state",
  "displayName": "Filter State",
  "description": "A simple example to filter the data to keep only the state indicated.",
  "functionName": "custom_filter_state",
  "parameters": [
    {
      "name": "colName",
      "displayName": "Column name",
      "type": "str",
      "description": "Name of the column in the data that holds the state postal code"
    },
    {
      "name": "state",
      "displayName": "State postal code",
      "type": "str",
      "description": "The postal code of the state whole rows to keep"
    }
  ]
}
```

Pour implémenter le script compagnon en Python

1. Démarrez un AWS Glue bloc-notes et exécutez la cellule initiale fournie pour démarrer la session. L'exécution de la cellule initiale crée les composants de base nécessaires.
2. Créez une fonction qui procède au filtrage, comme décrit dans l'exemple, et enregistrez-la sur `DynamicFrame`. Copiez le code ci-dessous et collez-le dans une cellule du AWS Glue carnet.

```
from awsglue import DynamicFrame

def custom_filter_state(self, colName, state):
    return self.filter(lambda row: row[colName] == state)

DynamicFrame.custom_filter_state = custom_filter_state
```

3. Créez ou chargez des exemples de données pour tester le code dans la même cellule ou dans une nouvelle cellule. Si vous ajoutez les exemples de données dans une nouvelle cellule, n'oubliez pas d'exécuter la cellule. Par exemple :

```
# A few of rows of sample data to test
data_sample = [
    {"state": "CA", "count": 4},
    {"state": "NY", "count": 2},
    {"state": "WA", "count": 3}
]
df1 = glueContext.sparkSession.sparkContext.parallelize(data_sample).toDF()
dynf1 = DynamicFrame.fromDF(df1, glueContext, None)
```

4. Test pour valider « `custom_filter_state` » avec différents arguments :

```
[14]: dynf1.custom_filter_state("state", "NY").show()
      {"count": 2, "state": "NY"}
```

5. Après avoir effectué plusieurs tests, enregistrez le code avec l'extension `.py` et attribuez au fichier `.py` le même nom que le fichier `.json`. Les fichiers `.py` et `.json` doivent se trouver dans le même dossier de transformations.

Copiez le code suivant, collez-le dans un fichier et renommez celui-ci avec l'extension de fichier `.py`.

```
from awsglue import DynamicFrame

def custom_filter_state(self, colName, state):
    return self.filter(lambda row: row[colName] == state)

DynamicFrame.custom_filter_state = custom_filter_state
```

6. Entrée AWS Glue Studio, ouvrez une tâche visuelle et ajoutez-y la transformation en la sélectionnant dans la liste des transformations disponibles.

Pour réutiliser cette transformation dans le code d'un script Python, ajoutez le chemin d'accès Amazon S3 au fichier .py dans la tâche située sous « Referenced files path » (Chemin des fichiers référencés) et, dans le script, importez le nom du fichier Python (sans l'extension) en l'ajoutant en haut du fichier. Par exemple : `import <nom du fichier (sans l'extension)>`

Étape 3. Valider et résoudre les problèmes liés aux transformations visuelles personnalisées dans AWS Glue Studio

AWS Glue Studio valide le fichier de configuration JSON avant le chargement des transformations visuelles personnalisées dans AWS Glue Studio. La validation inclut :

- Présence de champs obligatoires
- Validation du format JSON
- Paramètres incorrects ou non valides
- Présence des fichiers .py et .json au même emplacement Amazon S3
- Correspondance des noms de fichiers .py et .json.

Si la validation aboutit, la transformation est répertoriée dans la liste des Actions disponibles de l'éditeur visuel. Si une icône personnalisée a été fournie, elle doit être visible à côté de l'action.

Si la validation échoue, AWS Glue Studio ne charge pas la transformation visuelle personnalisée.

Étape 4 : Mettre à jour les transformations visuelles personnalisées selon les besoins

Une fois créé et utilisé, le script de transformation peut être mis à jour tant que la transformation respecte la définition json correspondante :

- Le nom utilisé lors de l'attribution d'une DynamicFrame trop grande valeur correspond au `jsonfunctionName`.
- Les arguments de la fonction doivent être définis dans le fichier json comme décrit dans [Étape 1. Créer un fichier de configuration JSON](#).
- Le chemin d'accès Amazon S3 au fichier Python ne peut pas être modifié, car les tâches en dépendent directement.

Note

Si des mises à jour sont nécessaires, veillez à ce que le script et le fichier .json soient mis à jour en conséquence et à ce que toutes les tâches visuelles soient correctement enregistrées avec la nouvelle transformation. Si les tâches visuelles ne sont pas enregistrées à l'issue des mises à jour, ces dernières ne sont ni appliquées ni validées. Si le fichier de script Python est renommé ou s'il n'est pas placé à côté du fichier .json, vous devez spécifier le chemin d'accès complet dans le fichier .json.

Icône personnalisée

Si vous déterminez que l'icône par défaut de votre action ne la distingue pas visuellement dans le cadre de vos flux de travail, vous pouvez fournir une icône personnalisée, comme décrit dans [the section called “ Premiers pas avec les transformations visuelles personnalisées ”](#). Vous pouvez mettre à jour l'icône en mettant à jour le fichier SVG correspondant hébergé sur Amazon S3.

Pour de meilleurs résultats, concevez votre image pour qu'elle soit affichée en 32 × 32 pixels en suivant les directives de Cloudscape Design System. Pour plus d'informations sur les directives Cloudscape, consultez la [documentation Cloudscape](#).

Étape 5. Utilisez des transformations visuelles personnalisées dans AWS Glue Studio

Pour utiliser une transformation visuelle personnalisée dans AWS Glue Studio, vous chargez les fichiers de configuration et source, puis vous sélectionnez la transformation dans le menu Action. Tous les paramètres nécessitant des valeurs ou des entrées sont disponibles dans l'onglet Transform (Transformation).

1. Chargez les deux fichiers (fichier source Python et fichier de configuration JSON) dans le dossier de ressources Amazon S3 où sont stockés les scripts de travail. Par défaut, AWS Glue extrait tous les fichiers JSON du dossier `/transform` dans le même compartiment Amazon S3.

2. Dans le menu Action, sélectionnez la transformation visuelle personnalisée. Celle-ci porte le `displayName` ou le nom de la transformation que vous avez spécifié dans le fichier de configuration `.json`.
3. Entrez des valeurs pour tous les paramètres qui ont été définis dans le fichier de configuration.

The screenshot shows the AWS Glue console interface for configuring a custom transformation. The left pane displays a visual workflow with a 'Data source - S3 bucket Amazon S3' node connected to a 'Transform - Dynamic Trans... My Transform' node. The right pane shows the 'Transform' configuration tab, which includes a form with the following fields:

- Email Address**: Enter your work email address below (text input)
- Phone Number**: Enter your mobile phone number below (text input)
- Your age**: (text input)
- Your gender**: (dropdown menu)
- Your origin country ? - optional**: What country were you born in? (dropdown menu with 'Choose options' as the selected value)
- Do you want to receive promotional newsletter from us? - optional**: (checkbox)

Exemples d'utilisation

L'exemple suivant présente tous les paramètres possibles pour un fichier de configuration `.json`.

```
{
  "name": "MyTransform",
  "displayName": "My Transform",
  "description": "This transform description will be displayed in UI",
  "functionName": "myTransform",
  "parameters": [
    {
      "name": "email",
      "displayName": "Email Address",
      "type": "str",
      "description": "Enter your work email address below",
      "validationType": "RegularExpression",
      "validationRule": "^[\\w+([\\.-]?\\w+)*@[\\w+([\\.-]?\\w+)*\\.\\w{2,3})+$",
      "validationMessage": "Please enter a valid email address"
    },
    {
      "name": "phone",
```

```

    "displayName": "Phone Number",
    "type": "str",
    "description": "Enter your mobile phone number below",
    "validationRule": "^\\((?\\d{3})\\)?[- ]?(\\d{3})[- ]?(\\d{4})$",
    "validationMessage": "Please enter a valid US number"
  },
  {
    "name": "age",
    "displayName": "Your age",
    "type": "int",
    "isOptional": true
  },
  {
    "name": "gender",
    "displayName": "Your gender",
    "type": "str",
    "listOptions": [
      {"label": "Male", "value": "male"},
      {"label": "Female", "value": "female"},
      {"label": "Other", "value": "other"}
    ],
    "isOptional": true
  },
  {
    "name": "country",
    "displayName": "Your origin country ?",
    "type": "list",
    "listOptions": "Afghanistan,Albania,Algeria,American
Samoa,Andorra,Angola,Anguilla,Antarctica,Antigua and
Barbuda,Argentina,Armenia,Aruba,Australia,Austria,Azerbaijan,Bahamas,Bahrain,Bangladesh,Barbados
and Herzegovina,Botswana,Bouvet Island,Brazil,British Indian Ocean Territory,Brunei
Darussalam,Bulgaria,Burkina Faso,Burundi,Cambodia,Cameroon,Canada,Cape
Verde,Cayman Islands,Central African Republic,Chad,Chile,China,Christmas
Island,Cocos (Keeling Islands),Colombia,Comoros,Congo,Cook Islands,Costa
Rica,Cote D'Ivoire (Ivory Coast),Croatia (Hrvatska,Cuba,Cyprus,Czech
Republic,Denmark,Djibouti,Dominica,Dominican Republic,East Timor,Ecuador,Egypt,El
Salvador,Equatorial Guinea,Eritrea,Estonia,Ethiopia,Falkland Islands (Malvinas),Faroe
Islands,Fiji,Finland,France,France,Metropolitan,French Guiana,French Polynesia,French
Southern
Territories,Gabon,Gambia,Georgia,Germany,Ghana,Gibraltar,Greece,Greenland,Grenada,Guadeloupe,Guinea-Bissau,Guyana,Haiti,Heard and McDonald Islands,Honduras,Hong
Kong,Hungary,Iceland,India,Indonesia,Iran,Iraq,Ireland,Israel,Italy,Jamaica,Japan,Jordan,Kazakhstan
(North),Korea
(South),Kuwait,Kyrgyzstan,Laos,Latvia,Lebanon,Lesotho,Liberia,Libya,Liechtenstein,Lithuania,Luxembourg

```

```

Islands,Martinique,Mauritania,Mauritius,Mayotte,Mexico,Micronesia,Moldova,Monaco,Mongolia,Mont
Antilles,New Caledonia,New Zealand,Nicaragua,Niger,Nigeria,Niue,Norfolk
Island,Northern Mariana Islands,Norway,Oman,Pakistan,Palau,Panama,Papua
New Guinea,Paraguay,Peru,Philippines,Pitcairn,Poland,Portugal,Puerto
Rico,Qatar,Reunion,Romania,Russian Federation,Rwanda,Saint Kitts and Nevis,Saint
Lucia,Saint Vincent and The Grenadines,Samoa,San Marino,Sao Tome and Principe,Saudi
Arabia,Senegal,Seychelles,Sierra Leone,Singapore,Slovak Republic,Slovenia,Solomon
Islands,Somalia,South Africa,S. Georgia and S. Sandwich Isls.,Spain,Sri
Lanka,St. Helena,St. Pierre and Miquelon,Sudan,Suriname,Svalbard and Jan Mayen
Islands,Swaziland,Sweden,Switzerland,Syria,Tajikistan,Tanzania,Thailand,Togo,Tokelau,Tonga,Tri
and Tobago,Tunisia,Turkey,Turkmenistan,Turks and Caicos
Islands,Tuvalu,Uganda,Ukraine,United Arab Emirates,United Kingdom
(Britain / UK),United States of America (USA),US Minor Outlying
Islands,Uruguay,Uzbekistan,Vanuatu,Vatican City State (Holy See),Venezuela,Viet
Nam,Virgin Islands (British),Virgin Islands (US),Wallis and Futuna Islands,Western
Sahara,Yemen,Yugoslavia,Zaire,Zambia,Zimbabwe",
    "description": "What country were you born in?",
    "listType": "str",
    "isOptional": true
},
{
    "name": "promotion",
    "displayName": "Do you want to receive promotional newsletter from us?",
    "type": "bool",
    "isOptional": true
}
]
}

```

Exemples de scripts visuels personnalisés

Les exemples suivants effectuent des transformations équivalentes. Cela dit, le deuxième exemple (SparkSQL) est le plus propre et le plus efficace, suivi de l'exemple d'UDF Pandas et enfin du mappage de bas niveau du premier exemple. L'exemple suivant est une illustration complète de transformation simple permettant d'ajouter deux colonnes :

```

from awsglue import DynamicFrame

# You can have other auxiliary variables, functions or classes on this file, it won't
affect the runtime
def record_sum(rec, col1, col2, resultCol):
    rec[resultCol] = rec[col1] + rec[col2]

```

```

return rec

# The number and name of arguments must match the definition on json config file
# (expect self which is the current DynamicFrame to transform
# If an argument is optional, you need to define a default value here
# (resultCol in this example is an optional argument)
def custom_add_columns(self, col1, col2, resultCol="result"):
    # The mapping will alter the columns order, which could be important
    fields = [field.name for field in self.schema()]
    if resultCol not in fields:
        # If it's a new column put it at the end
        fields.append(resultCol)
    return self.map(lambda record: record_sum(record, col1, col2,
resultCol)).select_fields(paths=fields)

# The name we assign on DynamicFrame must match the configured "functionName"
DynamicFrame.custom_add_columns = custom_add_columns

```

L'exemple suivant illustre une transformation équivalente utilisant l'API SparkSQL.

```

from awsglue import DynamicFrame

# The number and name of arguments must match the definition on json config file
# (expect self which is the current DynamicFrame to transform
# If an argument is optional, you need to define a default value here
# (resultCol in this example is an optional argument)
def custom_add_columns(self, col1, col2, resultCol="result"):
    df = self.toDF()
    return DynamicFrame.fromDF(
        df.withColumn(resultCol, df[col1] + df[col2]) # This is the conversion logic
        , self.glue_ctx, self.name)

# The name we assign on DynamicFrame must match the configured "functionName"
DynamicFrame.custom_add_columns = custom_add_columns

```

L'exemple suivant utilise les mêmes transformations mais en utilisant une UDF Pandas, plus efficace qu'une UDF simple. Pour plus d'informations sur l'écriture de pandas, UDFs consultez la [documentation SQL d'Apache Spark](#).

```

from awsglue import DynamicFrame
import pandas as pd
from pyspark.sql.functions import pandas_udf

# The number and name of arguments must match the definition on json config file
# (expect self which is the current DynamicFrame to transform
# If an argument is optional, you need to define a default value here
# (resultCol in this example is an optional argument)
def custom_add_columns(self, col1, col2, resultCol="result"):
    @pandas_udf("integer") # We need to declare the type of the result column
    def add_columns(value1: pd.Series, value2: pd.Series) # pd.Series:
        return value1 + value2

    df = self.toDF()
    return DynamicFrame.fromDF(
        df.withColumn(resultCol, add_columns(col1, col2)) # This is the conversion
        logic
        , self.glue_ctx, self.name)

# The name we assign on DynamicFrame must match the configured "functionName"
DynamicFrame.custom_add_columns = custom_add_columns

```

Vidéo

La vidéo suivante contient une présentation des transformations visuelles personnalisées et de leur utilisation.

Utilisation des frameworks Data Lake avec AWS Glue Studio

Présentation

Les frameworks de lacs de données open source simplifient le traitement incrémentiel des données pour les fichiers stockés dans des lacs de données basés sur Amazon S3. AWS Glue Les versions 3.0 et ultérieures prennent en charge les frameworks de stockage de lacs de données open source suivants :

- Apache Hudi
- Linux Foundation Delta Lake
- Apache Iceberg

À compter du AWS Glue 4,0, AWS Glue fournit un support natif pour ces frameworks afin que vous puissiez lire et écrire les données que vous stockez dans Amazon S3 de manière cohérente sur le plan des transactions. Il n'est pas nécessaire d'installer un connecteur séparé ou d'effectuer des étapes de configuration supplémentaires pour utiliser ces frameworks dans AWS Glue emplois.

Les frameworks Data Lake peuvent être utilisés comme source ou cible dans AWS Glue Studio via les tâches de Spark Script Editor. Pour plus d'informations sur l'utilisation d'Apache Hudi, Apache Iceberg et Delta Lake, voir : [Utilisation des frameworks de data lake avec AWS Glue Emplois ETL](#).

Création de formats de tableau ouverts à partir d'une source de AWS Glue streaming

AWS Glue les tâches ETL de streaming consomment en permanence des données provenant de sources de streaming, nettoient et transforment les données en vol, et les rendent disponibles pour analyse en quelques secondes.

AWS propose une large gamme de services pour répondre à vos besoins. Un service de réplication de base de AWS données tel que Database Migration Service peut répliquer les données de vos systèmes sources vers Amazon S3, qui héberge généralement la couche de stockage du lac de données. Bien qu'il soit simple d'appliquer des mises à jour à un système de gestion de base de données relationnelle (RDBMS) qui soutient une application source en ligne, il est difficile d'appliquer ce processus CDC à vos lacs de données. Les cadres de gestion de données open source simplifient le traitement incrémentiel des données et le développement de pipelines de données et constituent une bonne option pour résoudre ce problème.

Pour plus d'informations, consultez :

- [Créez un lac de données near-real-time transactionnel basé sur Apache HUDI à l'aide du streaming AWS Glue](#)
- [Créer en temps réel un lac de données Apache Iceberg aligné sur le RGPD](#)


Utilisation du framework Hudi dans AWS Glue Studio

Lors de la création ou de la modification d'une tâche, AWS Glue Studio ajoute automatiquement les bibliothèques Hudi correspondantes pour vous en fonction de la version de AWS Glue vous utilisez. Pour plus d'informations, voir [Utilisation du framework Hudi dans AWS Glue](#).

Utilisation du cadre Apache Hudi dans les sources de données du catalogue de données

Pour ajouter un format de source de données Hudi à une tâche :

1. Dans le menu Source, choisissez AWS Glue Studio Catalogue de données.
2. Dans l'onglet Propriétés de source de données, choisissez une base de données et une table.
3. AWS Glue Studio affiche le type de format Apache Hudi et l'URL Amazon S3.



Utilisation du cadre Hudi dans les sources de données Amazon S3

1. Dans le menu Source, choisissez Amazon S3.
2. Si vous choisissez la table du catalogue de données comme type de source Amazon S3, choisissez une base de données et une table.
3. AWS Glue Studio affiche le format Apache Hudi et l'URL Amazon S3.
4. Si vous choisissez l'emplacement Amazon S3 comme Type de source Amazon S3, choisissez l'URL Amazon S3 en cliquant sur Parcourir Amazon S3.
5. Dans Format de données, sélectionnez Apache Hudi.

Note

If AWS Glue Studio n'est pas en mesure de déduire le schéma à partir du dossier ou du fichier Amazon S3 que vous avez sélectionné, choisissez Options supplémentaires pour sélectionner un nouveau dossier ou fichier.

Dans Options supplémentaires, choisissez l'une des options suivantes sous Inférence de schéma :

- Laisser AWS Glue Studio choisissez automatiquement un exemple de fichier — AWS Glue Studio choisira un exemple de fichier à l'emplacement Amazon S3 afin que le schéma puisse être déduit. Dans le champ Fichier auto-échantillonné, vous pouvez afficher le fichier sélectionné automatiquement.
- Choisir un exemple de fichier d'Amazon S3 : choisissez le fichier Amazon S3 à utiliser en cliquant sur Parcourir Amazon S3.

6. Cliquez sur Déduire un schéma. Vous pouvez ensuite consulter le schéma de sortie en cliquant sur l'onglet Schéma de sortie.
7. Choisissez Options supplémentaires pour saisir une paire clé-valeur.

Additional options [Info](#)

Enter additional key-value pairs for your data source connection.

Key

Value



Add new option

Utilisation du cadre Apache Hudi dans les cibles de données

Utilisation du cadre Apache Hudi dans les cibles de données du catalogue de données

1. Dans le menu Cible, choisissez AWS Glue Studio Catalogue de données.
2. Dans l'onglet Propriétés de source de données, choisissez une base de données et une table.
3. AWS Glue Studio affiche le type de format Apache Hudi et l'URL Amazon S3.

Utilisation du cadre Apache Hudi dans les cibles de données Amazon S3

Saisissez des valeurs ou sélectionnez-les parmi les options disponibles pour configurer le format Apache Hudi. Pour plus d'informations sur Apache Hudi, veuillez consulter la [documentation Apache Hudi](#).

Node properties

Data target properties - S3 2

Output schema

Data preview

Format

Apache Hudi

Hudi Table Name

Hudi Storage Type

☒ Copy on write

Recommended for optimizing read performance

☐ Merge on read

Recommended for minimizing write latency

Hudi Write Operation

Upsert

Hudi Record Key Fields

Set your primary key(s)

Select a source location to view schema

Hudi Deduplicate Records by Field Value

Set your field to choose the largest value when inserting records with duplicate key(s)

Select a source location to view schema

Compression Type

GZIP

S3 Target Location

Choose an S3 location in the format s3://bucket/prefix/object/ with a trailing slash (/).

View

Browse S3

Data Catalog update options

Info

Choose how you want to update the Data Catalog table's schema and partitions. These options will only apply if the Data Catalog table is an S3 backed source.

☒ Do not update the Data Catalog

☐ Create a table in the Data Catalog and on subsequent runs, update the schema and add new partitions

☐ Create a table in the Data Catalog and on subsequent runs, keep existing schema and add new partitions

Partition keys - optional

Add partition keys.

- Nom de la table Hudi : il s'agit du nom de votre table Hudi.
- Type de stockage Hudi : choisissez parmi deux options :
 - Copie à l'écriture : recommandé pour optimiser les performances de lecture. Il s'agit du type de stockage Hudi par défaut. Chaque mise à jour crée une nouvelle version des fichiers lors d'une écriture.
 - Fusion en lecture : recommandée pour minimiser la latence d'écriture. Les mises à jour sont consignées dans des fichiers delta basés sur les lignes et sont compressées si nécessaire pour créer de nouvelles versions des fichiers en colonnes.
- Opération d'écriture Hudi : choisissez parmi les options suivantes :
 - Upsert (mise à jour/insertion) : il s'agit de l'opération par défaut lors de laquelle les enregistrements d'entrée sont d'abord balisés comme des insertions ou des mises à jour en recherchant l'index. Recommandé lorsque vous mettez à jour des données existantes.
 - Insertion : permet d'insérer des enregistrements mais ne vérifie pas s'ils existent déjà, ce qui peut entraîner des doublons.
 - Insertion en bloc : permet d'insérer des enregistrements et est recommandée pour les grandes quantités de données.
- Champs de clé d'enregistrement Hudi : utilisez la barre de recherche pour rechercher et choisir les clés d'enregistrement primaires. Les enregistrements dans Hudi sont identifiés par une clé primaire qui est une paire de clé d'enregistrement et de chemin de partition à laquelle appartient l'enregistrement.
- Champ de précombinaison Hudi : il s'agit du champ utilisé lors de la précombinaison avant l'écriture réelle. Lorsque deux enregistrements ont la même valeur clé, AWS Glue Studio choisira celui dont la valeur est la plus élevée pour le champ de précombinaison. Définissez un champ auquel appartient une valeur incrémentielle (par exemple `updated_at`).
- Type de compression : choisissez l'une des options de type de compression suivantes : Uncompressed, GZIP, LZO ou Snappy.
- Emplacement cible Amazon S3 : choisissez l'emplacement cible Amazon S3 en cliquant sur Parcourir S3.
- Options de mise à jour du catalogue de données : choisissez parmi les options suivantes :
 - Do not update the Data Catalog (Ne pas mettre à jour le catalogue de données) : (valeur par défaut) choisissez cette option si vous ne souhaitez pas que la tâche mette à jour le catalogue de données, même si le schéma change ou si de nouvelles partitions sont ajoutées.
 - Créer une table dans le catalogue de données et lors des exécutions suivantes, mettre à jour le schéma et ajouter de nouvelles partitions : si vous choisissez cette option, la tâche crée la table

dans le catalogue de données lors de sa première exécution. Lors des exécutions de tâches ultérieures, la tâche met à jour la table du catalogue de données si le schéma change ou si de nouvelles partitions sont ajoutées.

Vous devez également sélectionner une base de données dans le catalogue de données et entrer un nom de table.

- Create a table in the Data Catalog and on subsequent runs, keep existing schema and add new partitions (Créer une table dans le catalogue de données et lors des exécutions suivantes, conserver le schéma existant et ajouter de nouvelles partitions) : si vous choisissez cette option, la tâche crée la table dans le catalogue de données lors de sa première exécution. Lors des exécutions de tâches ultérieures, la tâche met à jour la table du catalogue de données uniquement pour ajouter de nouvelles partitions.

Vous devez également sélectionner une base de données dans le catalogue de données et entrer un nom de table.

- Partition keys (Clé de partition) : choisissez les colonnes à utiliser comme clés de partitionnement dans la sortie. Pour ajouter d'autres clés de partition, choisissez Add a partition key (Ajouter une clé de partition).
- Options supplémentaires : saisissez une paire clé-valeur selon vos besoins.

Génération de code via AWS Glue Studio

Lorsque la tâche est enregistrée, les paramètres de tâche suivants sont ajoutés à la tâche si une source ou une cible Hudi est détectée :

- `--datalake-formats` : une liste distincte des formats de lacs de données détectés dans la tâche visuelle (soit directement en choisissant un « Format », soit indirectement en sélectionnant une table de catalogue soutenue par un lac de données).
- `--conf` : généré en fonction de la valeur des `--datalake-formats`. Par exemple, si la valeur pour `--datalake-formats` est « hudi », AWS Glue génère une valeur de `spark.serializer=org.apache.spark.serializer.KryoSerializer --conf spark.sql.hive.convertMetastoreParquet=false` pour ce paramètre.

Redéfinition AWS Glue-bibliothèques fournies

Pour utiliser une version de Hudi qui AWS Glue ne prend pas en charge, vous pouvez spécifier vos propres fichiers JAR de bibliothèque Hudi. Pour utiliser votre propre fichier JAR :

- utilisez le paramètre de tâche `--extra-jars`. Par exemple, `'--extra-jars': 's3pathtojarfile.jar'`. Pour plus d'informations, consultez [AWS Glue paramètres de la tâche](#).
- N'incluez pas `hudi` comme valeur du paramètre de tâche `--datalake-formats`. La saisie d'une chaîne vide comme valeur garantit qu'aucune bibliothèque de lacs de données ne vous est fournie par AWS Glue automatiquement. Pour plus d'informations, voir [Utilisation du framework Hudi dans AWS Glue](#).

Utilisation du framework Delta Lake dans AWS Glue Studio

Utilisation du cadre Delta Lake dans des sources de données

Utilisation du cadre Delta Lake dans des sources de données Amazon S3

1. Dans le menu Source, choisissez Amazon S3.
2. Si vous choisissez la table du catalogue de données comme type de source Amazon S3, choisissez une base de données et une table.
3. AWS Glue Studio affiche le format Delta Lake et l'URL Amazon S3.
4. Choisissez Options supplémentaires pour saisir une paire clé-valeur. Par exemple, une paire clé-valeur peut être : clé : `timestampAsOf` et valeur : `24/02/2023 14:16:18`.

Additional options [Info](#)

Enter additional key-value pairs for your data source connection.

Key

Value



Add new option

5. Si vous choisissez l'emplacement Amazon S3 comme Type de source Amazon S3, choisissez l'URL Amazon S3 en cliquant sur Parcourir Amazon S3.
6. Dans Format de données, choisissez Delta Lake.

 Note

If AWS Glue Studio n'est pas en mesure de déduire le schéma à partir du dossier ou du fichier Amazon S3 que vous avez sélectionné, choisissez Options supplémentaires pour sélectionner un nouveau dossier ou fichier.

Dans Options supplémentaires, choisissez l'une des options suivantes sous Inférence de schéma :

- Laisser AWS Glue Studio choisissez automatiquement un exemple de fichier — AWS Glue Studio choisira un exemple de fichier à l'emplacement Amazon S3 afin que le schéma puisse être déduit. Dans le champ Fichier auto-échantillonné, vous pouvez afficher le fichier sélectionné automatiquement.
- Choisir un exemple de fichier d'Amazon S3 : choisissez le fichier Amazon S3 à utiliser en cliquant sur Parcourir Amazon S3.

7. Cliquez sur Déduire un schéma. Vous pouvez ensuite consulter le schéma de sortie en cliquant sur l'onglet Schéma de sortie.

Utilisation du cadre Delta Lake dans des sources de données du catalogue de données

1. Dans le menu Source, choisissez AWS Glue Studio Catalogue de données.
2. Dans l'onglet Propriétés de source de données, choisissez une base de données et une table.
3. AWS Glue Studio affiche le type de format Delta Lake et l'URL Amazon S3.

 Note

Si votre source de Delta Lake n'est pas enregistrée en tant que AWS Glue Tableau du catalogue de données : deux options s'offrent à vous :

1. Créez un AWS Glue crawler pour le magasin de données de Delta Lake. Pour plus d'informations, veuillez consulter la rubrique [Comment préciser les options de configuration pour un magasin de données Delta Lake](#).
2. Utilisez une source de données Amazon S3 pour sélectionner votre source de données Delta Lake. Consultez [Utilisation du cadre Delta Lake dans des sources de données Amazon S3](#).

Utilisation des formats Delta Lake dans des cibles de données

Utilisation des formats Delta Lake dans des cibles de données du catalogue de données

1. Dans le menu Cible, choisissez AWS Glue Studio Catalogue de données.
2. Dans l'onglet Propriétés de source de données, choisissez une base de données et une table.
3. AWS Glue Studio affiche le type de format Delta Lake et l'URL Amazon S3.

Utilisation des formats Delta Lake dans des sources de données Amazon S3

Saisissez des valeurs ou sélectionnez-les parmi les options disponibles pour configurer le format Delta Lake.

- Type de compression : choisissez l'une des options de type de compression : Uncompressed ou Snappy.
- Emplacement cible Amazon S3 : choisissez l'emplacement cible Amazon S3 en cliquant sur Parcourir S3.
- Options de mise à jour du catalogue de données : la mise à jour du catalogue de données n'est pas prise en charge pour ce format dans l'éditeur visuel Glue Studio.
 - Do not update the Data Catalog (Ne pas mettre à jour le catalogue de données) : (valeur par défaut) choisissez cette option si vous ne souhaitez pas que la tâche mette à jour le catalogue de données, même si le schéma change ou si de nouvelles partitions sont ajoutées.
 - Pour mettre à jour le catalogue de données après AWS Glue exécution, exécution ou planification d'une tâche AWS Glue chenille. Pour plus d'informations, veuillez consulter la rubrique [Comment préciser les options de configuration pour un magasin de données Delta Lake](#).
- Clés de partition : choisissez les colonnes à utiliser comme clés de partitionnement dans la sortie. Pour ajouter d'autres clés de partition, choisissez Add a partition key (Ajouter une clé de partition).
- Choisissez éventuellement Options supplémentaires pour saisir une paire clé-valeur. Par exemple, une paire clé-valeur peut être : clé : timestampAsOf et valeur : 24/02/2023 14:16:18.

Utilisation du framework Apache Iceberg dans AWS Glue Studio

Utilisation du cadre Apache Iceberg dans les cibles de données

Utilisation du cadre Apache Iceberg dans les cibles de données du catalogue de données

1. Dans le menu Cible, choisissez AWS Glue Studio Catalogue de données.
2. Dans l'onglet Propriétés de source de données, choisissez une base de données et une table.
3. AWS Glue Studio affiche le type de format Apache Iceberg et l'URL Amazon S3.

Utilisation du cadre Apache Iceberg dans les cibles de données Amazon S3

Saisissez des valeurs ou sélectionnez-les parmi les options disponibles pour configurer le format Apache Iceberg.

- Format : choisissez Apache Iceberg dans le menu déroulant.
- Emplacement cible Amazon S3 : choisissez l'emplacement cible Amazon S3 en cliquant sur Parcourir S3.
- Options de mise à jour du catalogue de données : créer une table dans le catalogue de données et lors des exécutions suivantes, conserver le schéma existant et ajouter de nouvelles partitions doivent être sélectionnés pour continuer. Écrire une nouvelle table Iceberg à l'aide de AWS Glue nécessite le Data Catalog à configurer en tant que catalogue pour la table Iceberg. Pour mettre à jour une table Iceberg existante qui a été enregistrée dans le Data Catalog, choisissez Data Catalog comme cible.
- Base de données — Choisissez la base de données dans Data Catalog.
- Nom de table : saisissez la valeur pour votre nom de table. Les noms des tables Apache Iceberg doivent être entièrement en minuscules. Utilisez des traits de soulignement si nécessaire, car les espaces ne sont pas autorisés. Par exemple « data_lake_format_tables ».

Node properties	Data target properties - S3	Output schema	Data preview
-----------------	-----------------------------	---------------	--------------

Format

Apache Iceberg

Compression Type

GZIP

S3 Target Location

Choose an S3 location in the format s3://bucket/prefix/object/ with a trailing slash (/).

Q s3://data-lake-format-data/output/ X View Browse S3

Data Catalog update options

Choose how you want to update the Data Catalog table's schema and partitions. These options will only apply if the Data Catalog table is an S3 backed source.

☐ Do not update the Data Catalog
☐ Create a table in the Data Catalog and on subsequent runs, update the schema and add new partitions
☒ Create a table in the Data Catalog and on subsequent runs, keep existing schema and add new partitions

Database

Choose the database from the AWS Glue Data Catalog.

data_lake_format_tables

► Use runtime parameters

Table name

Enter a table name for the AWS Glue Data Catalog.

my_new_table

Utilisation du cadre Apache Iceberg dans les sources de données Amazon S3

Utilisation du cadre Apache Iceberg dans les sources de données du catalogue de données

1. Dans le menu Source, choisissez AWS Glue Studio Catalogue de données.
2. Dans l'onglet Propriétés de source de données, choisissez une base de données et une table.
3. AWS Glue Studio affiche le type de format Apache Iceberg et l'URL Amazon S3.

Node properties	Data source properties - S3	Output schema	Data preview
S3 source type ☐ S3 location Choose a file or folder in an S3 bucket. ☒ Data Catalog table Database Choose a database. data_lake_format_tables ▼  Table source_iceberg ▼  Format Apache Iceberg S3 URL s3://data-lake-format-data/iceberg/  Partition predicate - optional Enter a boolean expression supported by Spark SQL, using only partition columns. Partition predicate syntax for Spark SQL is <code>year == year(date_sub(current_date, 7)) AND month == month(date_sub(current_date, 7)) AND day == day(date_sub(current_date, 7))</code>.			

Utilisation du cadre Apache Iceberg dans les sources de données Amazon S3

Apache Iceberg n'est pas disponible en tant qu'option de données pour les nœuds source Amazon S3 dans AWS Glue Studio.

Se connecter aux sources de données à l'aide de tâches ETL visuelles

Lors de la création d'une nouvelle tâche, vous pouvez utiliser des connexions pour vous connecter aux données lorsque vous modifiez des tâches ETL visuelles dans AWS Glue. Vous pouvez le faire en ajoutant des nœuds source qui utilisent des connecteurs pour lire les données, et des nœuds cibles pour spécifier l'emplacement d'écriture des données.

Rubriques

- [Modifier les propriétés d'un nœud de source de données](#)
- [Utilisation des tables du catalogue de données pour la source de données](#)
- [Utilisation d'un connecteur pour la source de données](#)
- [Utilisation de fichiers dans Amazon S3 pour la source de données](#)
- [Utilisation d'une source de données en streaming](#)
- [Références](#)

Modifier les propriétés d'un nœud de source de données

Pour spécifier les propriétés de la source de données, vous devez d'abord choisir un nœud de source de données dans le diagramme de tâche. Ensuite, sur le côté droit du volet de détails du nœud, vous configurez les propriétés du nœud.

Pour modifier les propriétés d'un nœud de source de données

1. Accédez à l'éditeur visuel pour une tâche nouvelle ou sauvegardée.
2. Choisissez un nœud de source de données dans le diagramme de tâche.
3. Choisissez l'onglet Node properties (Propriétés de nœud) dans le volet de détails du nœud, puis entrez les informations suivantes :
 - Name (Nom) : (facultatif) saisissez un nom à associer au nœud dans le diagramme des tâches. Ce nom doit être unique parmi tous les nœuds de cette tâche.
 - Node type (Type de nœud) : le type de nœud détermine l'action effectuée par le nœud. Dans la liste des options pour Node type (Type de nœud), choisissez l'une des valeurs répertoriées sous l'en-tête Data source (Source de données).
4. Configurer les informations de Data source properties (Propriétés de source de données). Pour plus d'informations, consultez les sections suivantes :
 - [Utilisation des tables du catalogue de données pour la source de données](#)
 - [Utilisation d'un connecteur pour la source de données](#)
 - [Utilisation de fichiers dans Amazon S3 pour la source de données](#)
 - [Utilisation d'une source de données en streaming](#)
5. (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de la source de données, vous pouvez afficher le schéma de votre source de données en sélectionnant l'onglet

Output Schema (Schéma de sortie) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Si vous n'avez pas spécifié de rôle IAM dans le Job détails (Détails de la tâche), vous y êtes invité à ce stade.

6. (Facultatif) Après avoir configuré les propriétés du nœud et les propriétés de la source de données, vous pouvez prévisualiser le jeu de données à partir de votre source de données en sélectionnant l'onglet Data preview (Prévisualisation des données) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Il y a un coût associé à l'utilisation de cette fonction, et la facturation commence dès que vous fournissez le rôle IAM.

Utilisation des tables du catalogue de données pour la source de données

Pour toutes les sources de données, à l'exception d'Amazon S3 et des connecteurs, une table doit exister dans AWS Glue Data Catalog pour le type de source que vous choisissez. AWS Glue ne crée pas la table du catalogue de données.

Pour configurer un nœud de source de données basé sur une table de catalogue de données

1. Accédez à l'éditeur visuel pour une tâche nouvelle ou sauvegardée.
2. Choisissez un nœud de source de données dans le diagramme de tâche.
3. Choisissez l'onglet Data source properties (Propriétés de source de données), puis saisissez les informations suivantes :
 - Type de source S3 : (pour les sources de données Amazon S3 uniquement) Choisissez l'option Sélectionnez une table de catalogue pour utiliser une table existante AWS Glue Data Catalog table.
 - Database (Base de données) : choisissez la base de données dans le catalogue de données qui contient la table source que vous souhaitez utiliser pour cette tâche. Vous pouvez utiliser le champ de recherche pour rechercher une base de données par son nom.
 - Table : choisissez la table associée aux données source depuis la liste. Ce tableau doit déjà exister dans le AWS Glue Data Catalog. Vous pouvez utiliser le champ de recherche pour rechercher une table par son nom.
 - Partition predicate (Prédicat de partition) : (pour les sources de données Amazon S3 uniquement) saisissez une expression booléenne basée sur Spark SQL qui inclut uniquement les colonnes de partitionnement. Par exemple : "(year=='2020' and month=='04')"

- Temporary directory (Répertoire temporaire) : (pour les sources de données Amazon Redshift uniquement) saisissez un chemin d'accès pour l'emplacement d'un répertoire de travail dans Amazon S3 où votre tâche ETL peut écrire des résultats intermédiaires temporaires.
- Role associated with the cluster (Rôle associé au cluster) : (pour les sources de données Amazon Redshift uniquement) saisissez un rôle que votre tâche ETL doit utiliser qui contient des autorisations pour les clusters Amazon Redshift . Pour de plus amples informations, veuillez consulter [the section called “Autorisations de source et de cible de données”](#).

Utilisation d'un connecteur pour la source de données

Si vous sélectionnez un connecteur pour Node type (Type de nœud), suivez les instructions figurant dans [Création de tâches avec des connecteurs personnalisés](#) pour terminer la configuration des propriétés de la source de données.

Utilisation de fichiers dans Amazon S3 pour la source de données

Si vous choisissez Amazon S3 comme source de données, vous pouvez choisir parmi :

- Une base de données et une table de catalogue de données.
- Un compartiment, un dossier ou un fichier dans Amazon S3.

Si vous utilisez un compartiment Amazon S3 comme source de données, AWS Glue détecte le schéma des données à l'emplacement spécifié à partir de l'un des fichiers ou en utilisant le fichier que vous spécifiez comme fichier d'exemple. La détection de schéma se produit lorsque vous utilisez le bouton Infer schema (Déduire le schéma). Si vous modifiez l'emplacement Amazon S3 ou l'exemple de fichier, vous devez choisir Infer schema (Déduire le schéma) à nouveau pour effectuer la détection du schéma à l'aide des nouvelles informations.

Pour configurer un nœud de source de données qui lit directement à partir de fichiers dans Amazon S3

1. Accédez à l'éditeur visuel pour une tâche nouvelle ou sauvegardée.
2. Choisissez un nœud de source de données dans le diagramme de tâches pour une source Amazon S3.
3. Choisissez l'onglet Data source properties (Propriétés de source de données), puis saisissez les informations suivantes :

- S3 source type (Type de source S3) : (pour les sources de données Amazon S3 uniquement) choisissez l'option S3 location (Emplacement S3).
- S3 URL (URL S3) : saisissez le chemin d'accès au compartiment, dossier ou fichier Amazon S3 contenant les données de votre tâche. Vous pouvez choisir Browse S3 (Parcourir S3) pour sélectionner le chemin d'accès à partir des emplacements disponibles pour votre compte.
- Récursif : choisissez cette option si vous le souhaitez AWS Glue pour lire des données à partir de fichiers situés dans des dossiers enfants à l'emplacement S3.

Si les dossiers enfants contiennent des données partitionnées, AWS Glue n'ajoute aucune information de partition spécifiée dans les noms de dossiers au catalogue de données.

Prenons l'exemple des dossiers suivants dans Amazon S3 :

```
S3://sales/year=2019/month=Jan/day=1
S3://sales/year=2019/month=Jan/day=2
```

Si vous choisissez Recursive et que vous sélectionnez le sales dossier comme emplacement S3, AWS Glue lit les données de tous les dossiers enfants, mais ne crée pas de partitions par année, par mois ou par jour.

- Data format (Format de données) : choisissez le format dans lequel les données sont stockées. Vous pouvez choisir entre JSON, CSV ou Parquet. La valeur que vous sélectionnez indique AWS Glue travail sur la façon de lire les données du fichier source.

 Note

Si vous ne sélectionnez pas le format approprié pour vos données, AWS Glue peut déduire correctement le schéma, mais la tâche ne sera pas en mesure d'analyser correctement les données du fichier source.

Vous pouvez saisir des options de configuration supplémentaires, selon le format que vous choisissez.

- JSON (notation JavaScript d'objet)
 - JsonPath: entrez un chemin JSON qui pointe vers un objet utilisé pour définir un schéma de table. Les expressions de chemin JSON font toujours référence à une structure JSON de la même manière que les XPath expressions sont utilisées en combinaison avec un document XML. Le « root member object (objet membre racine) » dans le chemin JSON

est toujours appelé \$, qu'il s'agisse d'un objet ou d'un tableau. Le chemin JSON peut être écrit en notation point ou en notation crochet.

Pour plus d'informations sur le chemin JSON, consultez [JsonPath](#) le GitHub site Web.

- Records in source files can span multiple lines (Les enregistrements dans les fichiers source peuvent s'étendre sur plusieurs lignes) : choisissez cette option si un même enregistrement peut couvrir plusieurs lignes dans le fichier CSV.
- CSV (valeurs séparées par des virgules)
 - Delimiter (Délimiteur) : saisissez un caractère pour indiquer ce qui sépare chaque entrée de colonne dans la ligne, par exemple, ; ou , .
 - Escape character (Caractère d'échappement) : saisissez un caractère utilisé comme caractère d'échappement. Ce caractère indique que le caractère qui suit immédiatement le caractère d'échappement doit être pris littéralement et ne doit pas être interprété comme un délimiteur.
 - Quote character (Caractère de citation, ou guillemet) : saisissez le caractère utilisé pour regrouper des chaînes distinctes en une seule valeur. Par exemple, choisissez Double quote (") Guillemet double (") si vous avez des valeurs telles que "This is a single value" dans votre fichier CSV.
 - Records in source files can span multiple lines (Les enregistrements dans les fichiers source peuvent s'étendre sur plusieurs lignes) : choisissez cette option si un même enregistrement peut couvrir plusieurs lignes dans le fichier CSV.
 - First line of source file contains column headers (La première ligne du fichier source contient les en-têtes de colonne) : choisissez cette option si la première ligne du fichier CSV contient des en-têtes de colonne au lieu de données.
- Parquet (stockage en colonnes Apache Parquet)

Il n'y a pas de paramètres supplémentaires à configurer pour les données stockées au format Parquet.

- Hudi Apache

Il n'y a aucun paramètre supplémentaire à configurer pour les données stockées au format Apache Hudi.

- Lac Delta

Il n'y a aucun paramètre supplémentaire à configurer pour les données stockées au format

Delta Lake

- Excel

Il n'y a aucun paramètre supplémentaire à configurer pour les données stockées au format Excel.

- Partition predicate (Prédicat de partition) : pour partitionner les données lues à partir de la source de données, saisissez une expression booléenne basée sur Spark SQL qui inclut uniquement les colonnes de partitionnement. Par exemple : "(year=='2020' and month=='04')"
- Options avancées : étendez cette section si vous le souhaitez AWS Glue pour détecter le schéma de vos données en fonction d'un fichier spécifique.
 - Inférence de schéma : choisissez l'option Choisissez un exemple de fichier dans S3 si vous souhaitez utiliser un fichier spécifique au lieu de laisser AWS Glue choisir un fichier. L'inférence de schéma n'est pas disponible pour la source Excel.
 - Auto-sampled file (Fichier auto-échantillonné) : saisissez le chemin d'accès au fichier dans Amazon S3 à utiliser pour déduire le schéma.

Si vous modifiez un nœud de source de données et modifiez l'exemple de fichier sélectionné, choisissez Reload schema (Recharger le schéma) pour détecter le schéma à l'aide du nouvel exemple de fichier.

4. Cliquez sur le bouton Infer schema (Déduire le schéma) pour détecter le schéma à partir des fichiers sources dans Amazon S3. Si vous modifiez l'emplacement Amazon S3 ou l'exemple de fichier, vous devez choisir Infer schema (Déduire le schéma) à nouveau pour déduire le schéma à l'aide des nouvelles informations.

Utilisation d'une source de données en streaming

Vous pouvez créer des tâches d'extraction, de transformation et de chargement en streaming (ETL) qui s'exécutent continuellement et consomment des données provenant de sources en streaming dans Amazon Kinesis Data Streams, Apache Kafka et Amazon Managed Streaming for Apache Kafka (Amazon MSK).

Pour configurer les propriétés d'une source de données en streaming

1. Accédez à l'éditeur de graphes visuels pour une tâche nouvelle ou sauvegardée.
2. Choisissez un nœud de source de données dans le graphe pour Kafka ou Kinesis Data Streams.

3. Choisissez l'onglet Data source properties (Propriétés de source de données), puis saisissez les informations suivantes :

Kinesis

- Kinesis source type (Type de source Kinesis) : Choisissez l'option Stream details (Détails du flux) pour utiliser un accès direct à la source de streaming ou choisissez Data catalog table (Table du catalogue de données) pour utiliser les informations qui y sont stockées.

Si vous choisissez Stream details (Détails du flux), spécifiez les informations supplémentaires suivantes.

- Emplacement du flux de données : choisissez si le flux est associé à l'utilisateur actuel ou à un autre utilisateur.
- Région : Choisissez l' Région AWS endroit où se trouve le flux. Ces informations sont utilisées pour construire l'ARN permettant d'accéder au flux de données.
- Stream ARN : entrez l'Amazon Resource Name (ARN) pour le flux de données Kinesis. Si le flux est situé dans le compte courant, vous pouvez choisir le nom du flux dans la liste déroulante. Vous pouvez utiliser le champ de recherche pour rechercher un flux de données par son nom ou son ARN.
- Data format (Format de données) : choisissez dans la liste le format utilisé par le flux de données.

AWS Glue détecte automatiquement le schéma à partir des données de streaming.

Si vous choisissez Data Catalog table (Table Catalogue de données), spécifiez les informations supplémentaires suivantes.

- Base de données : (Facultatif) Choisissez la base de données dans AWS Glue Catalogue de données qui contient le tableau associé à votre source de données de streaming. Vous pouvez utiliser le champ de recherche pour rechercher une base de données par son nom.
- Table : (facultatif) choisissez la table associée aux données source depuis la liste. Ce tableau doit déjà exister dans AWS Glue Catalogue de données. Vous pouvez utiliser le champ de recherche pour rechercher une table par son nom.
- Détecter le schéma : choisissez cette option pour avoir AWS Glue détecte le schéma à partir des données de streaming, plutôt que d'utiliser les informations du schéma dans une table du catalogue de données. Cette option est activée automatiquement si vous choisissez l'option Stream details (Détails du flux).

- **Starting position (Position de départ)** : Par défaut, la tâche ETL utilise l'option Earliest, ce qui signifie qu'elle lit les données en commençant par le plus ancien enregistrement disponible dans le flux. Vous pouvez plutôt choisir Dernière, qui indique que la tâche ETL doit commencer à lire juste après l'enregistrement le plus récent du flux.
- **Window size (Dimension de la fenêtre temporelle)** : Par défaut, votre tâche ETL traite et écrit les données dans des fenêtres de 100 secondes. Cela permet de traiter les données de manière efficace et d'effectuer des agrégations sur les données qui arrivent plus tard que prévu. Vous pouvez modifier la taille de cette fenêtre temporelle pour augmenter la ponctualité ou la précision de l'agrégation.

AWS Glue les tâches de streaming utilisent des points de contrôle plutôt que des signets de tâches pour suivre les données lues.

- **Connection options (Options de connexion)** : développez cette section pour ajouter des paires clé-valeur permettant de spécifier des options de connexion supplémentaires. Pour de plus amples informations sur les options que vous pouvez spécifier ici, veuillez consulter les rubriques [« connectionType »](#) : [« kinesis »](#) dans le Guide du développeur AWS Glue .

Kafka

- **Apache Kafka source (Source Apache Kafka)** : choisissez l'option Stream details (Détails du flux) pour utiliser l'accès direct à la source en streaming ou choisir Data Catalog table (Table du catalogue de données) pour utiliser les informations qui y sont stockées.

Si vous choisissez Data Catalog table (Table Catalogue de données), spécifiez les informations supplémentaires suivantes.

- **Base de données** : (Facultatif) Choisissez la base de données dans AWS Glue Catalogue de données qui contient le tableau associé à votre source de données de streaming. Vous pouvez utiliser le champ de recherche pour rechercher une base de données par son nom.
- **Table** : (facultatif) choisissez la table associée aux données source depuis la liste. Ce tableau doit déjà exister dans AWS Glue Catalogue de données. Vous pouvez utiliser le champ de recherche pour rechercher une table par son nom.
- **Détecter le schéma** : choisissez cette option pour avoir AWS Glue détecter le schéma à partir des données de streaming, plutôt que de stocker les informations du schéma dans une table du catalogue de données. Cette option est activée automatiquement si vous choisissez l'option Stream details (Détails du flux).

Si vous choisissez Stream details (Détails du flux), spécifiez les informations supplémentaires suivantes.

- Nom de la connexion : Choisissez AWS Glue connexion qui contient les informations d'accès et d'authentification pour le flux de données Kafka. Vous devez utiliser une connexion avec les sources de données en streaming Kafka. Si aucune connexion n'existe, vous pouvez utiliser AWS Glue console pour créer une connexion pour votre flux de données Kafka.
- Topic name (Nom de la rubrique) : entrez le nom de la rubrique à lire.
- Data format (Format de données) : choisissez le format à utiliser lors de la lecture de données à partir du flux d'événements Kafka.
- Starting position (Position de départ) : Par défaut, la tâche ETL utilise la commande Earliest (Au plus tôt), ce qui signifie qu'elle lit les données commençant par le plus ancien registre disponible dans le flux. Vous pouvez plutôt choisir Dernière, qui indique que la tâche ETL doit commencer à lire juste après l'enregistrement le plus récent du flux.
- Window size (Dimension de la fenêtre temporelle) : Par défaut, votre tâche ETL traite et écrit les données dans des fenêtres de 100 secondes. Cela permet de traiter les données de manière efficace et d'effectuer des agrégations sur les données qui arrivent plus tard que prévu. Vous pouvez modifier la taille de cette fenêtre temporelle pour augmenter la ponctualité ou la précision de l'agrégation.

AWS Glue les tâches de streaming utilisent des points de contrôle plutôt que des signets de tâches pour suivre les données lues.

- Connection options (Options de connexion) : développez cette section pour ajouter des paires clé-valeur permettant de spécifier des options de connexion supplémentaires. Pour de plus amples informations sur les options que vous pouvez spécifier ici, veuillez consulter les rubriques [« connectionType »](#) : [« kafka »](#) dans le Guide du développeur AWS Glue .

 Note

Les prévisualisations de données ne sont actuellement pas prises en charge pour les sources de données en streaming.

Références

Bonnes pratiques

- [Créez un pipeline de services ETL pour charger les données de manière incrémentielle depuis Amazon S3 jusqu'à l'utilisation Amazon RedshiftAWS Glue](#)

Programmation ETL

- [Types de connexion et options pour l'ETL dans AWS Glue](#)
- [JDBC connectionType values](#)
- [Options avancées pour le transfert de données vers et depuis Amazon Redshift](#)

Configuration des nœuds de données cible

La cible des données est l'endroit où la tâche écrit les données transformées.

Vue d'ensemble des options de cible de données

Votre cible de données (également appelée récepteur de données) peut avoir la valeur :

- S3 — La tâche écrit les données dans un fichier dans l'emplacement Amazon S3 que vous choisissez et dans le format que vous spécifiez.

Si vous configurez des colonnes de partition pour la cible de données, la tâche écrit le jeu de données dans Amazon S3 dans des répertoires basés sur la clé de partition.

- AWS Glue Data Catalog — La tâche utilise les informations associées à la table dans le catalogue de données pour écrire les données en sortie dans un emplacement cible.

Vous pouvez créer la table manuellement ou à l'aide de l'crawler. Vous pouvez également utiliser AWS CloudFormation pour créer des tables dans le catalogue de données.

- Un connecteur : un connecteur est un bout de code qui facilite la communication entre votre banque de données et AWS Glue. La tâche utilise le connecteur et la connexion associée pour écrire les données de sortie vers un emplacement cible. Vous pouvez soit vous abonner à un connecteur proposé dans AWS Marketplace, soit créer votre propre connecteur personnalisé. Pour plus d'informations, veuillez consulter [Ajouter des connecteurs à AWS Glue Studio](#)

Vous pouvez choisir de mettre à jour le catalogue de données lorsque votre tâche écrit sur une cible de données Amazon S3. Au lieu de demander à un crawler de mettre à jour le catalogue de données lorsque le schéma ou les partitions changent, cette option facilite la mise à jour de vos tables. Cette option simplifie le processus de mise à disposition de vos données à des fins analytiques en ajoutant éventuellement de nouvelles tables au catalogue de données, en mettant à jour les partitions de table et en mettant à jour le schéma de vos tables directement à partir de la tâche.

Modification du nœud de données cible

La cible des données est l'endroit où la tâche écrit les données transformées.

Pour ajouter ou configurer un nœud de données cible dans votre diagramme de tâches

1. (Facultatif) Si vous devez ajouter un nœud cible, choisissez Target (Cible) dans la barre d'outils en haut de l'éditeur visuel, puis choisissez S3 ou Glue Data Catalog (Catalogue de données Glue).
 - Si vous choisissez S3 comme cible, la tâche écrit le jeu de données dans un ou plusieurs fichiers de l'emplacement Amazon S3 que vous spécifiez.
 - Si vous choisissez AWS Glue Data Catalog comme cible, la tâche écrit dans un emplacement décrit par la table sélectionnée dans le catalogue de données.
2. Choisir un nœud de source de données dans le diagramme de tâche. Lorsque vous choisissez un nœud, le volet de détails du nœud apparaît sur le côté droit de la page.
3. Choisissez l'onglet Node properties (Propriétés du nœud), puis saisissez les informations suivantes :
 - Name (Nom) : entrez un nom à associer au nœud dans le diagramme de tâche.
 - Node type (Type de nœud) : une valeur doit déjà être sélectionnée, mais vous pouvez la modifier si nécessaire.
 - Node parents (Parents de nœud) : le nœud parent est le nœud du diagramme de tâche qui fournit les données en sortie que vous souhaitez écrire à l'emplacement cible. Pour un diagramme de tâches prérempli, le nœud cible doit déjà avoir le nœud parent sélectionné. Si aucun nœud parent n'est affiché, choisissez un nœud parent dans la liste.

Un nœud cible a un nœud parent unique.

4. Configurer les informations de Data target properties (Propriétés de cible de données). Pour plus d'informations, consultez les sections suivantes:

- [Utilisation d'Amazon S3 pour la cible de données](#)
 - [Utilisation des tables du catalogue de données pour la cible de données](#)
 - [Utilisation d'un connecteur pour la cible de données](#)
5. (Facultatif) Après avoir configuré les propriétés du nœud cible de données, vous pouvez afficher le schéma en sortie de vos données en sélectionnant l'onglet Output Schema (Schéma de sortie) dans le volet de détails du nœud. La première fois que vous choisissez cet onglet pour un nœud de votre tâche, vous êtes invité à fournir un rôle IAM pour accéder aux données. Si vous n'avez pas spécifié de rôle IAM dans le Job détails (Détails de la tâche), vous y êtes invité à ce stade.

Utilisation d'Amazon S3 pour la cible de données

Pour toutes les sources de données, à l'exception d'Amazon S3 et des connecteurs, une table doit exister dans AWS Glue Data Catalog pour le type de source que vous choisissez. AWS Glue Studio ne crée pas la table du catalogue de données.

Pour configurer un nœud cible de données qui écrit dans Amazon S3

1. Accédez à l'éditeur visuel pour une tâche nouvelle ou sauvegardée.
2. Choisissez un nœud de source de données dans le diagramme de tâche.
3. Choisissez l'onglet Data source properties (Propriétés de source de données), puis saisissez les informations suivantes :
 - Format : choisissez un format dans la liste. Les types de format disponibles pour les résultats de données sont les suivants :
 - JSON : notation JavaScript d'objets.
 - CSV : valeurs séparées par des virgules.
 - Avro : JSON binaire Apache Avro.
 - Parquet : un type de rédacteur de parquet personnalisé optimisé pour DynamicFrames le format de données. Au lieu de demander un schéma précalculé pour les données, il calcule et modifie le schéma de manière dynamique.
 - ORC : format Apache Optimized Row Columnar (ORC).
 - Apache Hudi : infrastructure de stockage open source pour lacs de données qui simplifie le traitement incrémentiel des données et le développement de pipelines de données.
 - Apache Iceberg : format de tableau performant qui fonctionne exactement comme un tableau SQL.

- Delta Lake : infrastructure de stockage de lacs de données open source qui vous aide à effectuer des transactions ACID, à adapter la gestion des métadonnées et à unifier le streaming et le traitement des données par lots.
- XML : langage de balisage extensible (XML).
- Tableau Hyper : la technologie de moteur de données en mémoire de Tableau.

Pour en savoir plus sur ces options de format, voir Options de [format pour les entrées et sorties ETL dans AWS Glue](#) dans le Manuel du développeur AWS Glue .

- Type de compression : vous pouvez choisir de compresser éventuellement les données à l'aide des types de fichiers CSVJSON, ou Parquet. La valeur par défaut est sans compression, ou Aucun.

Type de fichier	Compressions
JSON/CSV/XML	GZIP, BROTLI BZIP2, DEFLATE, Snappy LZ4
Parquet	Snappy, LZO LZ4, BROTLI, GZIP
ORC	Snappy, ZLIB, non compressé, LZO
Avro	GZIP, BROTLI BZIP2, DEFLATE, Snappy LZ4
Delta Lake	GZIP, BROTLI BZIP2, DEFLATE, Snappy LZ4
Apache Hudi	GZIP, LZO, Snappy
Apache Iceberg	GZIP, LZO, Snappy
Tableau Hyper	Aucun

- S3 Target Location (Emplacement de cible S3) : compartiment Amazon S3 et emplacement pour la sortie de données. Vous pouvez choisir le bouton Browse S3 (Parcourir S3) pour afficher les compartiments Amazon S3 auxquels vous avez accès et en choisir un comme cible.
- Options de mise à jour du catalogue de données

- Do not update the Data Catalog (Ne pas mettre à jour le catalogue de données) : (valeur par défaut) choisissez cette option si vous ne souhaitez pas que la tâche mette à jour le catalogue de données, même si le schéma change ou si de nouvelles partitions sont ajoutées.
- Create a table in the Data Catalog and on subsequent runs, update the schema and add new partitions (Créer une table dans le catalogue de données et lors des exécutions suivantes, mettre à jour le schéma et ajouter de nouvelles partitions) : si vous choisissez cette option, la tâche crée la table dans le catalogue de données lors de sa première exécution. Lors des exécutions de tâches ultérieures, la tâche met à jour la table du catalogue de données si le schéma change ou si de nouvelles partitions sont ajoutées.

Vous devez également sélectionner une base de données dans le catalogue de données et entrer un nom de table.

- Create a table in the Data Catalog and on subsequent runs, keep existing schema and add new partitions (Créer une table dans le catalogue de données et lors des exécutions suivantes, conserver le schéma existant et ajouter de nouvelles partitions) : si vous choisissez cette option, la tâche crée la table dans le catalogue de données lors de sa première exécution. Lors des exécutions de tâches ultérieures, la tâche met à jour la table du catalogue de données uniquement pour ajouter de nouvelles partitions.

Vous devez également sélectionner une base de données dans le catalogue de données et entrer un nom de table.

- Partitionnement des fichiers : Choisissez le type de partitionnement dans lequel vous souhaitez enregistrer la sortie.
- Génération automatique de fichiers (recommandé) : il s'agit de la valeur par défaut du nombre de fichiers générés.
- Sortie de fichiers multiples : Spécifiez le nombre de sorties de fichiers que vous souhaitez. Pour des performances optimales, utilisez la valeur par défaut du nombre de fichiers générée automatiquement.
- Partition keys (Clé de partition) : choisissez les colonnes à utiliser comme clés de partitionnement dans la sortie. Pour ajouter d'autres clés de partition, choisissez Add a partition key (Ajouter une clé de partition).

Le partitionnement de fichiers n'est pas pris en charge pour Tableau Hyper en tant que format cible.

Utilisation des tables du catalogue de données pour la cible de données

Pour toutes les sources de données, à l'exception d'Amazon S3 et des connecteurs, une table doit exister dans AWS Glue Data Catalog pour le type de cible que vous choisissez. AWS Glue Studio ne crée pas la table du catalogue de données.

Pour configurer les propriétés de données d'une cible qui utilise une table du catalogue de données

1. Accédez à l'éditeur visuel pour une tâche nouvelle ou sauvegardée.
2. Choisir un nœud de source de données dans le diagramme de tâche.
3. choisissez l'onglet Data target properties (Propriétés de cible de données), puis saisissez les informations suivantes :
 - Database (Base de données) : depuis la liste, choisissez la base de données contenant la table que vous souhaitez utiliser comme cible. Cette base de données doit déjà exister dans le catalogue de données.
 - Table : choisissez la table qui définit le schéma de vos données en sortie dans la liste. Cette table doit déjà exister dans le catalogue de données.

Une table dans le catalogue de données consiste en des noms de colonnes, des définitions de types de données, des informations de partition et d'autres métadonnées sur le jeu de données cible. Votre tâche écrit dans un emplacement décrit par cette table dans le catalogue de données.

Pour plus d'informations sur la création de tables dans le catalogue de données, veuillez consulter la rubrique [Définition de tables dans le catalogue de données](#) dans le Guide du développeur AWS Glue .

- Options de mise à jour du catalogue de données
 - Do not change table definition (Ne modifiez pas la définition de table) : (valeur par défaut) choisissez cette option si vous ne souhaitez pas que la tâche mette à jour le catalogue de données, même si le schéma change ou si de nouvelles partitions sont ajoutées.
 - Update schema and add new partitions (Mettre à jour le schéma et ajouter de nouvelles partitions) : si vous choisissez cette option, la tâche met à jour la table Catalogue de données si le schéma change ou si de nouvelles partitions sont ajoutées.
 - Keep existing schema and add new partitions (Conserver le schéma existant et ajouter de nouvelles partitions) : si vous choisissez cette option, la tâche met à jour la table Catalogue de données uniquement pour ajouter de nouvelles partitions.

- **Partition keys (Clé de partition)** : choisissez les colonnes à utiliser comme clés de partitionnement dans la sortie. Pour ajouter d'autres clés de partition, choisissez **Add a partition key (Ajouter une clé de partition)**.

Utilisation d'un connecteur pour la cible de données

Si vous sélectionnez un connecteur comme **Node type (Type de nœud)**, suivez les instructions figurant dans [Création de tâches avec des connecteurs personnalisés](#) pour terminer la configuration des propriétés de la cible de données.

Modification ou téléchargement d'un script de tâche

Utilisez la commande AWS Glue Studio éditeur visuel pour modifier le script de tâche ou télécharger votre propre script.

Vous pouvez utiliser l'éditeur visuel pour modifier les nœuds de tâches uniquement si les tâches ont été créées avec AWS Glue Studio. Si le travail a été créé à l'aide du AWS Glue console, via les commandes de l'API ou via l'interface de ligne de commande (CLI), vous pouvez utiliser l'éditeur de script dans AWS Glue Studio pour modifier le script de tâche, les paramètres et le calendrier. Vous pouvez également modifier le script d'une tâche créée dans AWS Glue Studio en convertissant le job en mode script uniquement.

Pour modifier le script de tâche ou télécharger votre propre script

1. Si vous créez une tâche, sur la page **Jobs (Tâches)**, choisissez l'option **Spark script editor (Éditeur de script Spark)** pour créer une tâche Spark ou l'option **Python Shell script editor (Éditeur de script shell Python)** pour créer une tâche shell Python. Vous pouvez soit écrire un nouveau script, soit en télécharger un existant. Si vous choisissez **Spark script editor (Éditeur de script Spark)**, vous pouvez écrire ou télécharger un script Scala ou Python. Si vous choisissez **Python Shell script editor (Éditeur de script shell Python)**, vous ne pouvez écrire ou télécharger qu'un script Python.

Après avoir choisi l'option de création d'une tâche, dans la section **Options** qui s'affiche, vous pouvez choisir soit de commencer avec un script de démarrage (**Create a new script with boilerplate code (Créez un script avec le code standard)**), soit de télécharger un fichier local à utiliser comme script de tâche.

Si vous avez choisi **Spark script editor (Éditeur de script Spark)**, vous pouvez télécharger des fichiers de script Python ou Scala. Les scripts Scala doivent avoir l'extension de fichier `.scala`.

Les scripts Python doivent être reconnus en tant que fichiers de type Python. Si vous choisissez Python Shell script editor (Éditeur de script shell Python), vous ne pouvez télécharger que des fichiers script Python.

Lorsque vous avez terminé vos choix, choisissez Create (Créer) pour créer la tâche et ouvrir l'éditeur visuel.

2. Accédez à l'éditeur de tâches visuel pour la nouvelle tâche ou la tâche enregistrée, puis choisissez l'onglet Script.
3. Si vous n'avez pas créé de tâche à l'aide de l'une des options d'éditeur de script et que vous n'avez jamais modifié le script d'une tâche existante, la propriété Script affiche l'en-têteScript (Locked — verrouillé). Cela signifie que l'éditeur de script est en mode lecture seule. Choisissez Edit Script (Modifier le script) pour déverrouiller le script à des fins d'édition.

Pour rendre le script modifiable, AWS Glue Studio convertit votre tâche d'une tâche visuelle en une tâche basée uniquement sur des scripts. Si vous déverrouillez le script pour l'édition, vous ne pouvez plus utiliser l'éditeur visuel pour cette tâche après l'avoir sauvegardée.

Dans la fenêtre de confirmation, choisissez Confirm (Confirmer) pour continuer ou Cancel (Annuler) pour garder la tâche disponible pour l'édition visuelle.

Si vous choisissez Confirm (Confirmer), l'onglet Visual (Visuel) n'apparaît plus dans l'éditeur. Vous pouvez utiliser ... AWS Glue Studio pour modifier le script à l'aide de l'éditeur de script, modifier les détails ou le calendrier des tâches, ou afficher les exécutions des tâches.

 Note

Tant que vous n'avez pas enregistré la tâche, la conversion en tâche script-only n'est pas permanente. Si vous actualisez la page Web de la console ou fermez la tâche avant de l'enregistrer et la rouvrez dans l'éditeur visuel, vous pourrez toujours modifier les nœuds individuels dans l'éditeur visuel.

4. Modifiez le script en fonction des besoins.

Lorsque vous avez fini de modifier le script, choisissez Save (Enregistrer) pour sauvegarder la tâche et convertir définitivement la tâche de visuel à script-only.

5. (Facultatif) Vous pouvez télécharger le script depuis AWS Glue Studio console en cliquant sur le bouton Télécharger dans l'onglet Script. Lorsque vous cliquez sur ce bouton, une nouvelle fenêtre de navigateur s'ouvre et affiche le script à partir de son emplacement dans Amazon S3.

Les paramètres Script filename (Nom du fichier de script) et Script path (Chemin du script) de la tâche dans l'onglet Job details (Détails de la tâche) déterminent le nom et l'emplacement du fichier de script dans Amazon S3.

Join test job2

Visual

Script

Job details

Runs

Schedules

▼ Advanced properties

Script filename

Join test job.py

Script path

S3 location of the script. Path must be in the form s3://bucket/prefix/path/. It must end with a slash (/) and not include any files.

Q s3://aws-glue-assets-111122223333-t X

View

Browse S3

☐ Job metrics [Info](#)

Enable the creation of CloudWatch metrics when this job runs.

☒ Continuous logging [Info](#)

Enable logs in CloudWatch.

☒ Spark UI [Info](#)

Enable using Spark UI for monitoring this job.

Lorsque vous enregistrez le travail, AWS Glue enregistre le script de tâche à l'emplacement indiqué dans ces champs. Si vous modifiez le fichier de script à cet emplacement dans Amazon S3, AWS Glue Studio chargera le script modifié la prochaine fois que vous modifierez le job.

Création et modification de scripts Scala dans AWS Glue Studio

Lorsque vous choisissez l'éditeur de script pour créer une tâche, par défaut, le langage de programmation des tâches est défini sur Python ³. Si vous choisissez d'écrire un nouveau script au lieu de télécharger un script, AWS Glue Studio lance un nouveau script avec du texte standard écrit en Python. Si vous voulez écrire un script Scala à la place, vous devez d'abord configurer l'éditeur de script pour utiliser Scala.

 Note

Si vous choisissez Scala comme langage de programmation pour la tâche et que vous utilisez l'éditeur visuel pour concevoir votre tâche, le script de tâche généré est écrit en Scala, et aucune autre action n'est nécessaire.

Pour écrire un nouveau script Scala dans AWS Glue Studio

1. Créez une tâche en choisissant l'option Spark script editor (Éditeur de script Spark).
2. Sous Options, choisissez Create a new script with boilerplate code (Créez un script avec du code standard).
3. Choisissez l'onglet Job details (Détails de la tâche) et définissez Language (Langage) à Scala (au lieu de Python 3).

 Note

La propriété Type de la tâche est automatiquement définie à Spark lorsque vous choisissez l'option Spark script editor (Éditeur de script Spark) pour créer une tâche.

4. Choisissez l'onglet Script.
5. Supprimez le texte standard Python. Vous pouvez le remplacer par le texte standard Scala suivant.

```
import com.amazonaws.services.glue.{DynamicRecord, GlueContext}
import org.apache.spark.SparkContext
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job

object MyScript {
  def main(args: Array[String]): Unit = {
    val sc: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(sc)

  }
}
```

6. Écrivez votre script de tâche Scala dans l'éditeur. Ajoutez d'autres instructions `import` au besoin.

Création et modification de jobs shell Python dans AWS Glue Studio

Lorsque vous choisissez l'éditeur de script shell Python pour créer une tâche, vous pouvez télécharger un script Python existant ou en écrire un nouveau. Si vous choisissez d'écrire un nouveau script, le code standard est ajouté au nouveau script de tâche Python.

Pour créer une tâche shell Python

Reportez-vous aux instructions dans [Création d'un emploi dans AWS Glue Studio](#).

Les propriétés de tâche qui sont prises en charge pour les tâches shell Python ne sont pas les mêmes que celles prises en charge pour les tâches Spark. La liste suivante décrit les modifications apportées aux paramètres de tâche disponibles pour les tâches shell Python sur l'onglet Job details (Détails de la tâche).

- La propriété Type pour la tâche est automatiquement définie à `Python Shell` et ne peut pas être modifiée.
- Au lieu de Language (Langage), il y a une propriété Python version (Version de Python) pour la tâche. Actuellement, les jobs shell Python créés dans AWS Glue Studio utilisent Python 3.6.
- La propriété Glue version (Version de Glue) n'est pas disponible, car elle ne s'applique pas aux tâches shell Python.
- Au lieu de Worker type (Type d'employé) et Number of workers (Nombre d'employés), une propriété Data processing units (Unités de traitement des données) est affichée à la place. Cette propriété de tâche détermine le nombre d'unités de traitement de données (DPUs) consommées par le shell Python lors de l'exécution de la tâche.
- La propriété Job bookmark (Signet de tâche) n'est pas disponible, car elle n'est pas prise en charge pour les tâches shell Python.
- Sous Advanced properties (Propriétés avancées), les propriétés suivantes ne sont pas disponibles pour les tâches shell Python.
 - Métriques de tâche
 - Journalisation continue
 - Spark UI (Interface utilisateur Spark) et Spark UI logs path (Chemin d'accès à l'interface utilisateur Spark)

- Dependent jars path (Chemin des fichiers .jar dépendants), sous l'en-tête Libraries (Bibliothèques)

Modification des noeuds parents d'un nœud dans le diagramme de tâche

Vous pouvez modifier les parents d'un nœud pour déplacer des nœuds dans le diagramme de tâche ou pour modifier une source de données pour un nœud.

Pour modifier le nœud parent

1. Choisissez le nœud dans le diagramme de la tâche que vous souhaitez modifier.
2. Dans le volet de détails du nœud, dans l'onglet Node properties (Propriétés de nœud), sous l'en-tête Node parents (Parents de nœud), supprimez le parent actuel du nœud.
3. Choisissez un nouveau nœud parent dans la liste.
4. Modifiez les autres propriétés du nœud si nécessaire pour correspondre au nœud parent nouvellement sélectionné.

Si vous avez modifié un nœud par erreur, vous pouvez utiliser Undo (Annuler) de la barre d'outils pour inverser l'action.

Suppression de noeuds du diagramme de tâches

Lorsque vous travaillez avec des tâches Visual ETL, vous pouvez supprimer des nœuds du canevas sans avoir à ajouter à nouveau ou à restructurer les nœuds connectés au nœud supprimé.


Dans l'exemple ci-dessous, vous pouvez suivre en choisissant tâches ETL > Visual ETL, puis dans Exemples de tâches, en choisissant tâche Visual ETL pour joindre plusieurs sources. Choisissez Créer un exemple de tâche pour créer une tâche et suivez les étapes ci-dessous.

The screenshot shows the AWS Glue Studio interface. On the left, the navigation menu has 'Visual ETL' highlighted under 'ETL jobs'. The main panel is titled 'AWS Glue Studio' and shows options to 'Create job' (Visual ETL, Notebook, Script editor) and 'Example jobs' (Visual ETL job to join multiple sources, Ray notebook for parallelizing Python, Spark notebook using Pandas, Spark notebook using SQL). The 'Visual ETL job to join multiple sources' example is highlighted with a red box. At the bottom, the 'Your jobs (1)' table lists a job named 'job_101521' of type 'Glue ETL'.

Job name	Type	Last modified	AWS Glue version
job_101521	Glue ETL	1/31/2022, 11:44:06 AM	2.0

Pour supprimer un nœud du canevas

1. Dans la AWS Glue console, choisissez Visual ETL dans le menu de navigation et choisissez une tâche existante. Le canevas de tâches affiche l'exemple de tâche, comme illustré ci-dessous.



2. Choisissez le nœud que vous souhaitez supprimer. Le canevas zoomera sur le nœud. Dans la barre d'outils située sur le côté droit du canevas, cliquez sur l'icône de la corbeille. Cela supprimera le nœud et tout nœud connecté au nœud sera déplacé pour prendre sa place dans le flux de travail. Dans cet exemple, le premier nœud Join a été supprimé du canevas.

Si vous supprimez un nœud dans le flux de travail, vous AWS Glue réorganiserez les nœuds de manière à ce qu'ils ne se traduisent pas par un flux de travail non valide. Il se peut que vous deviez toujours corriger la configuration d'un nœud.

Dans l'exemple, le nœud Join situé sous le nœud Subscribers a été supprimé. Par conséquent, le nœud source Plans a été déplacé au niveau supérieur et est toujours connecté au nœud Join enfant. Le nœud Join nécessite désormais une configuration supplémentaire car Join nécessite deux nœuds source parents avec des tables sélectionnées. L'onglet Transformation situé à droite du canevas affiche l'exigence manquante dans les conditions de jointure.

Untitled job [↗](#)

Try new UI ⓘ Actions Save Run

Visual Script Job details Runs Data quality - updated Schedules Version Control

Transform

Name: Join

Node parents: Choose one or more parent node

Plan assignment X Subscribers X Plans X

S3 - DataSource S3 - DataSource S3 - DataSource

The parents of this node have overlapping field names. AWS Glue Studio can add an Apply Mapping node to rename them and avoid downstream issues.

Custom prefix: Add a prefix to the field names of the parent node on the right. right Resolve It


Join type: Select the type of join to perform. Inner join Select all rows from both datasets that meet the join con...

Join conditions: Select a field from each parent node for the join condition. Insufficient source nodes The Join transform requires two parent source nodes with selected tables.


Data preview Output schema

Node is misconfigured
Data preview will be displayed when following node is correctly configured:
• Join

3. Supprimez le deuxième nœud Join et le nœud Select Fields. Lorsque les nœuds ont été supprimés, le flux de travail ressemblera à l'exemple ci-dessous.



4. Pour modifier les connexions du nœud, cliquez sur la poignée du nœud et faites glisser la connexion vers un nouveau nœud. Cela vous permettra de supprimer des nœuds et de les réorganiser dans un flux logique. Dans l'exemple, une nouvelle connexion est établie en cliquant sur la poignée du nœud Plans et en faisant glisser la connexion vers le nœud Join, comme indiqué par la flèche rouge.



5. Si vous devez annuler une action, cliquez sur l'icône Annuler située juste en dessous de l'icône de la corbeille dans la barre d'outils située sur le côté droit du canevas.

Ajout de paramètres source et cible au AWS Glue Nœud de catalogue de données

AWS Glue Studio vous permet de paramétrer les tâches visuelles. Comme les noms des tables de catalogue peuvent être différents dans les environnements de production et de développement, vous pouvez définir et sélectionner des paramètres d'exécution pour les bases de données et les tables qui s'exécuteront lors de l'exécution de votre tâche.

Le paramétrage des tâches vous permet de paramétrer les sources et les cibles, et d'enregistrer ces paramètres dans la tâche lorsque vous utilisez le AWS Glue Nœud de catalogue de données. Lorsque vous spécifiez des sources et des cibles en tant que paramètres, vous activez la réutilisabilité des tâches, en particulier lorsque vous utilisez la même tâche dans plusieurs environnements. Cela s'avère utile lors de la promotion du code dans les environnements de

déploiement, en économisant en temps et en énergie lors de la gestion de vos sources et cibles. En outre, les paramètres personnalisés que vous spécifiez remplaceront tous les arguments par défaut pour des exécutions spécifiques de AWS Glue emplois.

Ajouter des paramètres source et cible

Que vous utilisiez le AWS Glue Nœud du catalogue de données en tant que source ou cible, vous pouvez définir les paramètres d'exécution dans la section Propriétés avancées de l'onglet Détails du Job.

1. Cliquez sur l'onglet AWS Glue Nœud du catalogue de données en tant que nœud source ou nœud cible.
2. Sélectionnez l'onglet Job details (Détails de la tâche).
3. Choisissez Advanced properties (Propriétés avancées).
4. Dans la section Job parameters (Paramètres de la tâche), saisissez une valeur clé. Par exemple, `--db.source` serait le paramètre d'une source de base de données. Vous pouvez saisir n'importe quel nom pour la clé, à condition que le nom de la clé soit suivi d'un « tiret ».

The screenshot displays the 'Job parameters' section of the AWS Glue console. It features a table with two columns: 'Key' and 'Value - optional'. Below the table is an 'Add new parameter' button and a message indicating that up to 49 more parameters can be added.

Key	Value - optional	
Enter key	Enter value	<button>Remove</button>

Add new parameter

You can add 49 more parameters.


5. Saisissez la valeur. Par exemple, `databasename` serait la valeur d'une source de base de données paramétrée.
6. Choisissez Add new parameter (Ajouter de nouveaux paramètres) si vous souhaitez ajouter d'autres paramètres. Un maximum de 50 paramètres est autorisé. Une fois que la paire clé-valeur a été définie, vous pouvez utiliser le paramètre dans AWS Glue Nœud de catalogue de données.

Sélectionner un paramètre d'exécution

Note

Le processus de sélection des paramètres d'exécution pour les bases de données et les tables est le même, que le AWS Glue Le nœud du catalogue de données est la source ou la cible.

1. Cliquez sur l'onglet AWS Glue Nœud du catalogue de données en tant que nœud source ou nœud cible.
2. Dans l'onglet Data source properties - Data Catalog (Propriétés de la source de données - Catalogue de données), sous Database (Base de données), choisissez Use runtime parameters (Utiliser les paramètres d'exécution).



The screenshot shows a dropdown menu with the text "▼ Use runtime parameters". Below the dropdown, the text "Select runtime parameter" is displayed. A note states: "Runtime parameters can be configured in the **Advanced properties** section on the **Job details** tab". Below this is a search input field with a downward arrow on the right. At the bottom, there are two buttons: "Apply" and "Clear".

3. Choisissez un paramètre dans le menu déroulant. Par exemple, lorsque vous sélectionnez un paramètre que vous avez défini pour une base de données source, la base de données est automatiquement renseignée dans le menu déroulant de la base de données lorsque vous choisissez Apply (Appliquer).
4. Dans la section Table, choisissez un paramètre que vous avez déjà défini comme table source. Lorsque vous choisissez Apply (Appliquer), la table est automatiquement renseignée en tant que table à utiliser.
5. Lorsque vous enregistrez et exécutez la tâche, AWS Glue Studio fera référence aux paramètres sélectionnés lors de l'exécution de la tâche.

Utilisation des systèmes de contrôle de version Git dans AWS Glue

Note

Les ordinateurs portables ne sont actuellement pas pris en charge pour le contrôle de version dans AWS Glue Studio. Toutefois, le contrôle de version pour AWS Glue les scripts de travail et les tâches ETL visuelles sont pris en charge.

Si vous disposez de référentiels distants et que vous souhaitez gérer votre AWS Glue tâches utilisant vos référentiels, vous pouvez utiliser AWS Glue Studio ou AWS CLI pour synchroniser les modifications apportées à vos référentiels et à vos tâches dans AWS Glue. Lorsque vous synchronisez les modifications de cette façon, vous redirigez la tâche depuis AWS Glue Studio vers votre dépôt, ou en extrayant du dépôt vers AWS Glue Studio.

Avec l'intégration de Git dans AWS Glue Studio, vous pouvez :

- Intégrez les systèmes de contrôle de version Git AWS CodeCommit, tels que GitHub, GitLab, et Bitbucket
- Modifier AWS Glue offres d'emploi dans AWS Glue Studio si vous utilisez des tâches visuelles ou des tâches de script et que vous les synchronisez avec un référentiel
- paramétrer les sources et les cibles dans les tâches ;
- Extraire les jobs d'un référentiel et les modifier dans AWS Glue Studio
- Testez les tâches en extrayant des succursales et/ou en les poussant vers des succursales à l'aide de flux de travail multisuccursales dans AWS Glue Studio
- Téléchargez des fichiers depuis un référentiel et chargez des tâches dans AWS Glue Studio pour la création d'emplois entre comptes
- Utilisez l'outil d'automatisation de votre choix (par exemple, Jenkins AWS CodeDeploy, etc.)

Cette vidéo montre comment intégrer AWS Glue à Git et créer un pipeline de code continu et collaboratif.

Autorisations IAM

Assurez-vous que la tâche dispose de l'une des autorisations IAM suivantes. Pour plus d'informations sur la façon de configurer les autorisations IAM, voir [Configurer les autorisations IAM pour AWS Glue Studio](#).

- `AWSGlueServiceRole`
- `AWSGlueConsoleFullAccess`

Au minimum, les actions suivantes sont nécessaires pour l'intégration de Git :

- `glue:UpdateJobFromSourceControl`— pour être en mesure de mettre à jour AWS Glue avec une tâche présente dans un système de contrôle de version
- `glue:UpdateSourceControlFromJob`— pour pouvoir mettre à jour le système de contrôle de version avec une tâche stockée dans AWS Glue
- `s3:GetObject` : pour pouvoir récupérer le script de la tâche tout en le transférant vers le système de contrôle de version
- `s3:PutObject` : pour pouvoir mettre à jour le script lors de l'extraction d'une tâche depuis un système de contrôle de source

Prérequis

Pour transférer des tâches vers un référentiel de contrôle de source, vous aurez besoin :

- d'un référentiel qui a déjà été créé par votre administrateur ;
- d'une branche dans le référentiel ;
- d'un jeton d'accès personnel (pour Bitbucket, il s'agit du jeton d'accès au référentiel) ;
- du nom d'utilisateur du propriétaire du référentiel ;
- définir des autorisations dans le référentiel pour autoriser AWS Glue Studio pour lire et écrire dans le référentiel
 - GitLab— définit les portées des jetons sur `api`, `read_repository` et `write_repository`
 - Bitbucket : définissez les autorisations suivantes :
 - Abonnement à Workspace : `read`, `write`
 - Projets : `write`, `admin read`
 - Référentiels : `read`, `write`, `admin`, `delete`

Note

Lors de l'utilisation AWS CodeCommit, le jeton d'accès personnel et le propriétaire du référentiel ne sont pas nécessaires. Consultez [Getting started with Git and AWS CodeCommit](#).

Utilisation des tâches de votre référentiel de contrôle de source dans AWS Glue Studio

Pour extraire une tâche de votre référentiel de contrôle de source qui ne se trouve pas dans AWS Glue Studio, et pour utiliser cette tâche dans AWS Glue Studio, les prérequis dépendront du type d'emploi.

Pour les tâches visuelles :

- Vous avez besoin d'un dossier et d'un fichier JSON contenant la définition de la tâche correspondant au nom de la tâche.

Par exemple, consultez la définition de la tâche ci-dessous. La branche de votre référentiel doit contenir un chemin `my-visual-job/my-visual-job.json` où le dossier et le fichier JSON correspondent au nom de la tâche.

```
{
  "name" : "my-visual-job",
  "description" : "",
  "role" : "arn:aws:iam::aws_account_id:role/Rolename",
  "command" : {
    "name" : "glueetl",
    "scriptLocation" : "s3://foldername/scripts/my-visual-job.py",
    "pythonVersion" : "3"
  },
  "codeGenConfigurationNodes" : "{ \"node-nodeID\" : { \"S3CsvSource\" :
{ \"AdditionalOptions\" : { \"EnableSamplePath\" : false, \"SamplePath\" : \"s3://notebook-
test-input/netflix_titles.csv\" }, \"Escaper\" : \"\", \"Exclusions\" : [], \"Name\" : \"Amazon
S3\", \"OptimizePerformance\" : false, \"OutputSchemas\" : [ { \"Columns\" : [ { \"Name\" :
\"show_id\", \"Type\" : \"string\" }, { \"Name\" : \"type\", \"Type\" : \"string\" }, { \"Name\" :
\"title\", \"Type\" : \"choice\" }, { \"Name\" : \"director\", \"Type\" : \"string\" }, { \"Name\" :
\"cast\", \"Type\" : \"string\" }, { \"Name\" : \"country\", \"Type\" : \"string\" }, { \"Name\" :
\"date_added\", \"Type\" : \"string\" }, { \"Name\" : \"release_year\", \"Type\" : \"bigint\" },
{ \"Name\" : \"rating\", \"Type\" : \"string\" }, { \"Name\" : \"duration\", \"Type\" : \"string
\" }, { \"Name\" : \"listed_in\", \"Type\" : \"string\" }, { \"Name\" : \"description\", \"Type
\" : \"string\" } ] } ], \"Paths\" : [ \"s3://dalamgir-notebook-test-input/netflix_titles.csv
```



```
\"] , \"QuoteChar\" : \"\\\"\", \"Recurse\" : true, \"Separator\" : \",\", \"WithHeader\" : true}}}"
}
```

Pour les tâches de script :

- vous avez besoin d'un dossier, d'un fichier JSON contenant la définition de la tâche, et du script.
- le dossier et le fichier JSON doivent correspondre au nom de la tâche. Le nom du script doit correspondre à `scriptLocation` dans la définition de la tâche avec l'extension de fichier.

Par exemple, dans la définition de la tâche ci-dessous, la branche de votre référentiel doit contenir un chemin `my-script-job/my-script-job.json` et `my-script-job/my-script-job.py`. Le nom du script doit correspondre au nom dans `scriptLocation` y compris l'extension du script.

```
{
  "name" : "my-script-job",
  "description" : "",
  "role" : "arn:aws:iam::aws_account_id:role/Rolename",
  "command" : {
    "name" : "glueetl",
    "scriptLocation" : "s3://foldername/scripts/my-script-job.py",
    "pythonVersion" : "3"
  }
}
```

Limites

- AWS Glue [ne prend actuellement pas en charge le pousser/le retrait depuis GitLab -Groups](#).

Connecter les référentiels de contrôle de version avec AWS Glue

Vous pouvez saisir les détails de votre référentiel de contrôle de version et les gérer dans l'onglet Contrôle de version du AWS Glue Studio éditeur de tâches. Pour intégrer votre dépôt Git, vous devez vous connecter à celui-ci chaque fois que vous vous connectez à AWS Glue Studio.

Pour connecter un système de contrôle de version Git :

1. Entrée AWS Glue Studio, lancez une nouvelle tâche et cliquez sur l'onglet Contrôle de version.

Untitled job 

Visual | **Script** | **Job details** | **Runs** | **Schedules** | **Version Control**

 Your job has not been committed to version control. If you wish to do so, choose the **Push to repository** option from the **Actions** dropdown.

Version control configuration Reset

Configure the version control system you want to associate with your job.

Version control system
Choose a version control system.

None ▼

2. Dans Système de contrôle de version, choisissez Git Service parmi les options disponibles en cliquant sur le menu déroulant.
 - AWS CodeCommit
 - GitHub
 - GitLab
 - Bitbucket
3. Selon le système de contrôle de version Git que vous choisissez, vous aurez différents champs à remplir.

Pour AWS CodeCommit :

Terminez la configuration du référentiel en sélectionnant le référentiel et la branche correspondant à votre tâche :

- Référentiel : si vous avez configuré des référentiels dans AWS CodeCommit, sélectionnez-les dans le menu déroulant. Vos référentiels apparaîtront automatiquement dans la liste

- Branche : sélectionnez la branche dans le menu déroulant
- Dossier : facultatif – Saisissez le nom du dossier dans lequel vous souhaitez enregistrer votre tâche. S'il est laissé vide, un dossier est automatiquement créé. Le nom du dossier est par défaut le nom de la tâche.

Pour GitHub :

Complétez la GitHub configuration en remplissant les champs suivants :

- Jeton d'accès personnel : il s'agit du jeton fourni par le GitHub référentiel. Pour plus d'informations sur les jetons d'accès personnels, voir [GitHub Docs](#)
- Propriétaire du dépôt : il s'agit du propriétaire du GitHub dépôt.

Terminez la configuration du référentiel en sélectionnant le référentiel et la branche depuis GitHub.

- Référentiel : si vous avez configuré des référentiels dans GitHub, sélectionnez-les dans le menu déroulant. Vos référentiels apparaîtront automatiquement dans la liste
- Branche : sélectionnez la branche dans le menu déroulant
- Dossier : facultatif – Saisissez le nom du dossier dans lequel vous souhaitez enregistrer votre tâche. S'il est laissé vide, un dossier est automatiquement créé. Le nom du dossier est par défaut le nom de la tâche.

Pour GitLab :

 Note

AWS Glue ne prend actuellement pas en charge le pousser/le retrait depuis GitLab - Groups.

- Jeton d'accès personnel : il s'agit du jeton fourni par le GitLab référentiel. Pour plus d'informations sur les jetons d'accès personnels, voir [Jetons d'accès GitLab personnels](#)
- Propriétaire du dépôt : il s'agit du propriétaire du GitLab dépôt.

Terminez la configuration du référentiel en sélectionnant le référentiel et la branche depuis GitLab.

- Référentiel : si vous avez configuré des référentiels dans GitLab, sélectionnez-les dans le menu déroulant. Vos référentiels apparaîtront automatiquement dans la liste
- Branche : sélectionnez la branche dans le menu déroulant
- Dossier : facultatif – Saisissez le nom du dossier dans lequel vous souhaitez enregistrer votre tâche. S'il est laissé vide, un dossier est automatiquement créé. Le nom du dossier est par défaut le nom de la tâche.

Pour Bitbucket :

- Mot de passe d'application : Bitbucket utilise des mots de passe d'application et non des jetons d'accès au référentiel. Pour plus d'informations sur les mots de passe des applications, consultez la section [Mots de passe des applications](#).
- Propriétaire du référentiel : il s'agit du propriétaire du référentiel Bitbucket. Dans Bitbucket, le propriétaire est le créateur du référentiel.

Terminez la configuration du référentiel en sélectionnant l'espace de travail, le référentiel, la branche et le dossier depuis Bitbucket.

- Espace de travail : si vous avez configuré des espaces de travail dans Bitbucket, sélectionnez l'espace de travail dans le menu déroulant. Vos espaces de travail sont automatiquement remplis.
- Référentiel : si vous avez configuré des référentiels dans Bitbucket, sélectionnez le référentiel dans le menu déroulant. Vos référentiels sont automatiquement remplis.
- Branche : sélectionnez la branche dans le menu déroulant. Vos branches sont automatiquement remplies.
- Dossier : facultatif – Saisissez le nom du dossier dans lequel vous souhaitez enregistrer votre tâche. Si elles sont laissées vides, un dossier est automatiquement créé avec le nom de la tâche.


4. Choisissez Enregistrer en haut de AWS Glue Studio tâche

Transmission AWS Glue tâches vers le référentiel source

Une fois que vous avez saisi les détails de votre système de contrôle de version, vous pouvez modifier les tâches dans AWS Glue Studio et transférez les tâches vers votre référentiel source. Si vous n'êtes pas familier avec les concepts de Git tels que le transfert et l'extraction, consultez ce didacticiel sur [Getting started with Git and AWS CodeCommit](#)

Pour transférer votre tâche vers un référentiel, vous devez saisir les détails de votre système de contrôle de version et enregistrer votre tâche.

1. Dans le volet AWS Glue Studiojob, choisissez Actions. Cette action ouvrira des options de menu supplémentaires.



2. Choisissez Push to repository.


Cette action permettra de sauvegarder la tâche. Lorsque vous envoyez un message au dépôt, AWS Glue Studio envoie la dernière modification enregistrée. Si la tâche du référentiel a été modifiée par vous ou par un autre utilisateur et qu'elle n'est pas synchronisée avec la tâche dans AWS Glue Studio, la tâche du référentiel est remplacée par la tâche enregistrée dans AWS Glue Studio lorsque vous repoussez le travail de AWS Glue Studio.

3. Choisissez Confirm (Confirmer) pour terminer l'action. Cette action crée une validation dans le référentiel. Si vous l'utilisez AWS CodeCommit, un message de confirmation affichera un lien vers le dernier commit activé AWS CodeCommit.

Tirant AWS Glue jobs depuis le référentiel source

Une fois que vous avez saisi les détails de votre dépôt Git dans l'onglet Contrôle de version, vous pouvez également extraire des jobs de votre dépôt et les modifier dans AWS Glue Studio.

1. Dans le volet AWS Glue Studio job, choisissez Actions. Cette action ouvrira des options de menu supplémentaires.



2. Choisissez Pull from repository (Extraire depuis le référentiel).
3. Choisissez Confirmer. Cela prend le dernier commit du référentiel et met à jour votre travail dans AWS Glue Studio.
4. Modifiez votre offre d'emploi dans AWS Glue Studio. Si vous apportez des modifications, vous pouvez synchroniser votre tâche avec votre référentiel en choisissant Push to repository dans le menu déroulant Actions.

Création de code avec AWS Glue Studio blocs-notes

Les ingénieurs de données peuvent créer AWS Glue des tâches plus rapides et plus faciles qu'auparavant grâce à l'interface interactive du bloc-notes dans AWS Glue Studio ou des sessions interactives dans AWS Glue.

Limites

- AWS Glue Studio les ordinateurs portables ne supportent pas Scala.

Rubriques

- [Présentation de l'utilisation des blocs-notes](#)
- [Création d'une tâche ETL à l'aide de blocs-notes dans AWS Glue Studio](#)
- [Composants de l'éditeur de bloc-notes](#)
- [Enregistrement de votre bloc-notes et de votre script de tâche](#)
- [Gestion des séances de bloc-notes](#)
- [Utilisation d'Amazon Q Developer avec AWS Glue Studio blocs-notes](#)

Présentation de l'utilisation des blocs-notes

AWS Glue Studio vous permet de créer des tâches de manière interactive dans une interface de bloc-notes basée sur Jupyter Notebooks. Grâce à des carnets de notes dans AWS Glue Studio, vous pouvez modifier des scripts de travail et afficher le résultat sans avoir à exécuter un travail complet, et vous pouvez modifier le code d'intégration des données et afficher le résultat sans avoir à exécuter un travail complet, et vous pouvez ajouter du markdown et enregistrer des blocs-notes sous forme de fichiers .ipynb et de scripts de travail. Vous pouvez démarrer un bloc-notes sans installation locale de logiciels ni gestion de serveurs. Lorsque vous êtes satisfait de votre code, AWS Glue Studio vous pouvez convertir votre bloc-notes en une tâche Glue en un seul clic.

Les avantages liés à l'utilisation des bloc-notes sont les suivants :

- Aucun cluster à allouer ou à gérer
- Aucun cluster inactif à payer
- Aucune configuration préalable n'est requise
- Aucune installation de bloc-notes Jupyter n'est requise
- Même environnement d'exécution/plateforme que AWS Glue ETL

Lorsque vous démarrez un bloc-notes via AWS Glue Studio, toutes les étapes de configuration sont effectuées pour vous afin que vous puissiez explorer vos données et commencer à développer votre script de travail en quelques secondes seulement. AWS Glue Studio configure un bloc-notes Jupyter

avec le AWS Glue Noyau de Jupiter. Vous n'avez pas besoin de configurer VPCs de connexions réseau ou de terminaux de développement pour utiliser ce bloc-notes.

Pour créer des tâches à l'aide de l'interface du bloc-notes :

- configurez les autorisations IAM nécessaires.
- démarrez une séance de bloc-notes pour créer une tâche
- écrivez un code dans les cellules du bloc-notes
- exécutez et testez le code pour afficher le résultat
- sauvegardez la tâche

Une fois que votre bloc-notes est enregistré, il est plein AWS Glue travail. Vous pouvez gérer tous les aspects de la tâche, tels que la programmation de l'exécution des tâches, la définition des paramètres de tâche et l'affichage de l'historique des exécutions de tâches directement à côté de votre bloc-notes.

Création d'une tâche ETL à l'aide de blocs-notes dans AWS Glue Studio

Pour commencer à utiliser des blocs-notes dans le AWS Glue Studio console

1. Joignez AWS Identity and Access Management des politiques au AWS Glue Studio utilisateur et créez un rôle IAM pour votre tâche ETL et votre bloc-notes.
2. Configurez une sécurité IAM supplémentaire pour les blocs-notes, comme décrit dans [Octroi d'autorisations pour le rôle IAM](#).
3. Ouvrez le fichier AWS Glue Studio console à <https://console.aws.amazon.com/gluestudio/>.

Note

Vérifiez que votre navigateur ne bloque pas les cookies tiers. Tout navigateur qui bloque les cookies tiers par défaut ou en tant que paramètre activé par l'utilisateur empêchera le lancement des bloc-notes. Pour en savoir plus sur la gestion des cookies, voir :

- [Chrome](#)
- [Firefox](#)
- [Safari](#)

4. Choisissez le lien Tâches dans le menu de navigation de gauche.
5. Choisissez Bloc-notes Jupyter, puis choisissez Créer pour démarrer une nouvelle séance de bloc-notes.
6. Dans la page Créer une tâche dans le bloc-notes Jupyter, indiquez le nom de la tâche, puis choisissez le rôle IAM à utiliser. Choisissez Créer une tâche.

Après un court laps de temps, l'éditeur de bloc-notes apparaît.

7. Après avoir ajouté le code, vous devez exécuter la cellule pour démarrer une séance. Il existe plusieurs façons d'exécuter la cellule :
 - Appuyez sur le bouton Lecture.
 - Utilisez un raccourci clavier :
 - Sur macOS, Command (Commande) + Enter (Entrée) pour exécuter la cellule.
 - Sous Windows, Shift + Enter (Entrée) pour exécuter la cellule.

Pour plus d'informations sur l'écriture de code à l'aide d'une interface de notebook Jupyter, voir la [Documentation utilisateur de Jupyter Notebook](#).

8. Pour tester votre script, exécutez l'intégralité du script ou des cellules individuelles. Toute sortie de commande sera affichée dans la zone située sous la cellule.
9. Une fois que vous avez fini de développer votre bloc-notes, vous pouvez enregistrer la tâche, puis l'exécuter. Vous pouvez trouver ce script dans l'onglet Script. Toutes les magies que vous avez ajoutées au bloc-notes seront supprimées et ne seront pas enregistrées dans le cadre du script généré AWS Glue travail. AWS Glue Studio ajoutera automatiquement un `job.commit()` à la fin du script généré à partir du contenu du bloc-notes.

Pour de plus amples informations sur l'exécution d'une tâche, veuillez consulter [Démarrer une exécution de tâche](#).

Composants de l'éditeur de bloc-notes

L'interface de l'éditeur de bloc-notes comporte les sections principales suivantes.

- Interface de bloc-notes (panneau principal) et barre d'outils
- Onglets d'édition de tâches

L'éditeur de bloc-notes

Le AWS Glue Studio L'éditeur de bloc-notes est basé sur l'application Jupyter Notebook. Le AWS Glue Studio l'interface du bloc-notes est similaire à celle fournie par Jupyter Notebooks, décrite dans la section Interface utilisateur du [bloc-notes](#). Le bloc-notes utilisé par les séances interactives est un bloc-notes Jupyter.

Bien que le AWS Glue Studio L'ordinateur portable est similaire aux ordinateurs portables Jupyter, il diffère de plusieurs manières principales :

- actuellement, le AWS Glue Studio l'ordinateur portable ne peut pas installer d'extensions
- vous ne pouvez pas utiliser plusieurs onglets ; il existe une relation 1:1 entre une tâche et un bloc-notes
- le AWS Glue Studio le bloc-notes n'a pas le même menu de fichiers supérieur que celui qui existe dans Jupyter Notebooks
- actuellement, le AWS Glue Studio l'ordinateur portable ne fonctionne qu'avec le AWS Glue noyau. Notez que vous ne pouvez pas mettre à jour le noyau par vous-même.

AWS Glue Studio onglets d'édition de tâches

Les onglets que vous utilisez pour interagir avec la tâche ETL se trouvent en haut de la page du bloc-notes. Ils sont similaires aux onglets qui apparaissent dans l'éditeur visuel de tâches de AWS Glue Studio, et ils exécutent les mêmes actions.

- Bloc-notes – Utilisez cet onglet pour afficher le script de tâche à l'aide de l'interface bloc-notes.
- Détails de la tâche – configurez l'environnement et les propriétés des exécutions de travaux.
- Exécutions – Affichez des informations sur les exécutions précédentes de cette tâche.
- Planificateurs – Configurez un planificateurs d'exécution de votre tâche à des moments précis.

Enregistrement de votre bloc-notes et de votre script de tâche

Vous pouvez enregistrer votre bloc-notes et le script de tâche que vous créez à tout moment. Il suffit de choisir le bouton Enregistrer dans le coin supérieur droit, comme si vous utilisiez l'éditeur visuel ou de script.

Lorsque vous choisissez Save (Enregistrer), le fichier bloc-notes est enregistré dans les emplacements par défaut :

- Par défaut, le script de tâche est enregistré à l'emplacement Amazon S3 indiqué dans l'onglet Job Details (Détails de la tâche), sous Advanced properties (Propriétés avancées), dans la propriété Détails de la tâche Script path (Chemin du script). Les scripts de tâches sont enregistrés dans un sous-dossier nommé `Scripts`.
- Par défaut, le fichier du bloc-notes (`.ipynb`) est enregistré à l'emplacement Amazon S3 indiqué dans l'onglet Job Details (Détails de la tâche), sous Advanced properties (Propriétés avancées), dans les Détails de la tâche Script path (Chemin du script). Les fichiers de blocs-notes sont enregistrés dans un sous-dossier nommé `Notebooks`.

Note

Lorsque vous enregistrez la tâche, le script de tâche contient uniquement les cellules de code du bloc-notes. Les cellules Markdown et les magies ne sont pas incluses dans le script de tâche. Cependant, le fichier `.ipynb` contiendra tous les markdown et les magies.

Une fois la tâche enregistrée, vous pouvez ensuite l'exécuter à l'aide du script que vous avez créé dans le bloc-notes.

Gestion des séances de bloc-notes

Carnets en AWS Glue Studio sont basés sur la fonctionnalité de sessions interactives de AWS Glue. L'utilisation de sessions interactives est payante. Pour gérer vos coûts, vous pouvez contrôler les séances créées pour votre compte et configurer les paramètres par défaut de toutes les séances.

Modifier le délai d'expiration par défaut pour toutes les séances de bloc-notes

Par défaut, le provisionné AWS Glue Studio le bloc-notes expire au bout de 12 heures s'il a été lancé et qu'aucune case n'a été exécutée. Il n'y a aucun coût associé et le délai d'expiration n'est pas configurable.

Une fois que vous avez exécuté une cellule, une session interactive démarre. Cette session a un délai d'expiration par défaut de 48 heures. Ce délai d'expiration peut être configuré en entrant un champ magique `%idle_timeout` avant d'exécuter une cellule.

Pour modifier le délai d'expiration de session par défaut pour les blocs-notes dans AWS Glue Studio

1. Dans le bloc-notes, entrez le champ magique `%idle_timeout` dans une cellule et spécifiez la valeur du délai d'attente en minutes.

2. Par exemple : `%idle_timeout 15` modifiera le délai d'expiration par défaut à 15 minutes. Si la séance n'est pas utilisée pendant 15 minutes, la séance est automatiquement arrêtée.

Installation de modules Python supplémentaires

Si vous souhaitez installer des modules supplémentaires à votre séance à l'aide de pip, vous pouvez le faire en utilisant `%additional_python_modules` pour les ajouter à votre séance :

```
%additional_python_modules awswrangler, s3://amzn-s3-demo-bucket/mymodule.whl
```

Tous les arguments de `additional_python_modules` sont transmis à `pip3 install -m <>`

Pour une liste des modules Python disponibles, voir [Utilisation des bibliothèques Python avec AWS Glue](#).

Évolution AWS Glue Configuration

Vous pouvez utiliser la magie pour contrôler AWS Glue valeurs de configuration des tâches. Si vous souhaitez modifier une valeur de configuration de tâche, vous devez utiliser magic appropriée dans le bloc-notes. Voir [Magics soutenu par AWS Glue sessions interactives pour Jupyter](#).

Note

Le remplacement des propriétés d'une session en cours d'exécution n'est plus disponible. Pour modifier les configurations de la session, vous pouvez arrêter la session, définir les nouvelles configurations, puis démarrer une nouvelle session.

AWS Glue prend en charge différents types de travailleurs. Vous pouvez définir le type d'employé avec `%worker_type`. Par exemple : `%worker_type G.2X` . La valeur par défaut est G.1X.

Vous pouvez également spécifier le nombre d'employés avec `%number_of_workers`. Par exemple, pour spécifier 40 employés : `%number_of_workers 40`.

Pour de plus amples informations, veuillez consulter la rubrique [Définir les propriétés d'une tâche](#).

Arrêt d'une séance de bloc-notes

Pour arrêter une séance de bloc-notes, utilisez la magie `%stop_session`.

Si vous quittez le bloc-notes dans la AWS console, vous recevrez un message d'avertissement dans lequel vous pourrez choisir d'arrêter la session.

Utilisation d'Amazon Q Developer avec AWS Glue Studio blocs-notes

AWS Glue Studio vous permet de créer des tâches de manière interactive dans une interface de bloc-notes basée sur les blocs-notes Jupyter. L'utilisation d'Amazon Q Developer améliore l'expérience de création au sein de AWS Glue Studio carnets.

L'extension Amazon Q Developer prend en charge l'écriture de code en générant des recommandations de code et en suggérant des améliorations liées aux problèmes de code. Amazon Q Developer prend en charge Python et Scala, les deux langages utilisés pour coder les scripts ETL pour les tâches Spark dans AWS Glue Studio carnets.

Qu'est-ce qu'Amazon Q Developer ?

Amazon Q Developer est un service basé sur l'apprentissage automatique qui permet d'améliorer la productivité des développeurs. Amazon Q Developer y parvient en générant des recommandations de code basées sur les commentaires des développeurs en langage naturel et leur code dans l'IDE. Le service s'intègre à Amazon SageMaker AI Studio JupyterLab, aux instances de Amazon SageMaker AI bloc-notes et à d'autres environnements de développement intégrés (IDEs).

Pour plus d'informations, consultez [Utilisation d'Amazon Q Developer avec AWS Glue Studio](#).

AWS Glue états d'exécution des tâches sur la console

Vous pouvez consulter le statut d'un AWS Glue tâche d'extraction, de transformation et de chargement (ETL) pendant son exécution ou après son arrêt. Vous pouvez consulter le statut à l'aide du AWS Glue console. Pour de plus amples informations sur les états d'exécution des tâches, consultez [the section called “Statuts d'exécution de la tâche”](#).

Accès au tableau de bord de surveillance de tâche

Vous accédez au tableau de bord de suivi des tâches en cliquant sur le lien de surveillance de l'exécution des tâches dans le AWS Glue volet de navigation sous les tâches ETL.

Présentation du tableau de bord de surveillance de tâche

Le tableau de bord de surveillance de tâche fournit un récapitulatif global des exécutions de tâches, avec des totaux pour les tâches dont le statut est Running (En cours d'exécution), Canceled (Annulé),

Success (Succès), ou Failed (Échec). Des vignettes supplémentaires fournissent le taux de réussite global de l'exécution des tâches, l'utilisation estimée du DPU pour les tâches, une ventilation des comptes de statut des tâches par type de tâche, type d'employé et par jour.

Les graphiques dans les vignettes sont interactifs. Vous pouvez choisir n'importe quel bloc d'un graphique pour exécuter un filtre qui affiche uniquement ces tâches dans le tableau Job runs (Exécutions de tâche) au bas de la page.

Vous pouvez modifier la plage de dates des informations affichées sur cette page à l'aide du sélecteur Date range (Plage de dates). Lorsque vous modifiez la plage de dates, les vignettes d'informations s'ajustent pour afficher les valeurs du nombre de jours spécifié avant la date actuelle. Vous pouvez également utiliser une plage de dates spécifique si vous sélectionnez Custom (Personnalisée) à partir du sélecteur de plage de dates.

Vue des exécutions de tâche

Note

L'historique d'exécution des tâches est accessible pendant 90 jours pour votre flux de travail et l'exécution des tâches.

La liste des ressources Job runs (Exécutions de tâche) affiche les tâches pour la plage de dates et les filtres spécifiés.

Vous pouvez filtrer les tâches en fonction de critères supplémentaires, tels que le statut, le type d'employé, le type de tâche et le nom de la tâche. Dans la zone de filtre située en haut du tableau, vous pouvez saisir le texte à utiliser comme filtre. Les résultats du tableau sont mis à jour avec des lignes qui contiennent du texte correspondant lorsque vous saisissez le texte.

Vous pouvez afficher un sous-ensemble des tâches en choisissant des éléments dans les graphiques du tableau de bord de surveillance de tâche. Par exemple, si vous choisissez le nombre de tâches en cours d'exécution dans la liste Job runs summary (Résumé des exécutions de tâches), la vignette Job runs (Exécutions de tâche) affiche uniquement les tâches dont le statut est actuellement Running. Si vous choisissez l'une des barres du diagramme à barres Worker type breakdown (Répartition par type d'employé), seules les exécutions de tâche dont le type et le statut d'employé correspondent sont affichées dans la liste Job runs (Exécutions de tâche).

La liste de ressources Job runs (Exécutions de tâche) affiche les détails des exécutions de tâche. Vous pouvez trier les lignes du tableau en choisissant un en-tête de colonne. Le tableau contient les informations suivantes :

Propriété	Description
Nom de la tâche	Nom de la tâche .
Type	Le type d'environnement de la tâche : • Glue ETL : s'exécute dans un environnement Apache Spark géré par AWS Glue. • Glue Streaming : s'exécute dans un environnement Apache Spark et exécute ETL sur des flux de données. • Shell Python : exécute les scripts Python en tant que shell.
L'heure de début	Date et heure auxquelles cette exécution de tâche a démarré.
L'heure de fin	Date et heure auxquelles cette exécution de tâche s'est terminée.
Statut de l'exécution	État actuel de l'exécution de tâche. Les valeurs peuvent être : • STARTING • RUNNING • STOPPING • STOPPED • SUCCEEDED • FAILED • TIMEOUT
Durée de l'exécution	Le temps pendant lequel l'exécution de la tâche a consommé des ressources.

Propriété	Description
Capacité	Le nombre de AWS Glue unités de traitement de données (DPU) allouées pour cette exécution de tâche. Pour plus d'informations sur la planification des capacités, consultez la section Surveillance de la planification de la capacité du DPU dans AWS Glue Guide du développeur.

Propriété	Description
Type d'employé	Type d'employé prédéfini qui est alloué lorsqu'une tâche est exécutée. Les valeurs peuvent être G.1X, G.2X, G.4X ou G.8X. • G.1X – Lorsque vous choisissez ce type, vous devez également fournir une valeur pour Number of workers (Nombre d'employés). Chaque utilisateur est mappé sur 1 DPU (4 VCPUs, 16 Go de mémoire) avec un disque de 84 Go (environ 34 Go libres). Nous vous recommandons ce type d'employé pour les tâches utilisant beaucoup de mémoire. Il s'agit du type de travailleur par défaut pour AWS Glue Tâches en version 2.0 ou ultérieure. • G.2X – Lorsque vous choisissez ce type, vous devez également fournir une valeur pour Number of workers (Nombre d'employés). Chaque utilisateur mappe sur 2 processeurs (8 VCPUs, 32 Go de mémoire) avec un disque de 128 Go (environ 77 Go libres). Nous vous recommandons ce type d'employé pour des tâches qui requiert beaucoup de mémoire et des tâches qui effectuent des transformations Machine Learning. • G.4X – Lorsque vous choisissez ce type, vous devez également fournir une valeur pour Number of workers (Nombre d'employés). Chaque utilisateur mappe sur 4 processeurs (16 VCPUs, 64 Go de mémoire) avec un disque de 256 Go (environ 235 Go libres). Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégatio

Propriété	Description
	ns, les jointures et les requêtes les plus exigeantes. Ce type de travailleur n'est disponible que pour AWS Glue version 3.0 ou ultérieure Spark ETL jobs dans les AWS régions suivantes : USA Est (Ohio), USA Est (Virginie du Nord), USA Ouest (Oregon), Asie-Pacifique (Singapour), Asie-Pacifique (Sydney), Asie-Pacifique (Tokyo), Canada (Centre), Europe (Francfort), Europe (Irlande) et Europe (Stockholm). • G.8X – Lorsque vous choisissez ce type, vous devez également fournir une valeur pour Number of workers (Nombre d'employés). Chaque utilisateur mappe sur 8 DPU (32 VCPUs, 128 Go de mémoire) avec un disque de 512 Go (environ 487 Go libres). Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes. Ce type de travailleur n'est disponible que pour AWS Glue jobs Spark ETL version 3.0 ou ultérieure, dans les mêmes AWS régions que celles prises en charge pour le type de G.4X travailleur.
Heures DPU	Nombre estimé d'unités DPUs utilisées pour l'exécution de la tâche. Un DPU est une mesure relative de la puissance de traitement. DPUs sont utilisés pour déterminer le coût de fonctionnement de votre travail. Pour de plus amples informations, veuillez consulter le .AWS Glue page de tarification.

Vous pouvez sélectionner n'importe quelle exécution de tâche dans la liste et afficher des informations supplémentaires. Choisissez une exécution de tâche, puis procédez comme suit :

- Sélectionnez le menu Actions, puis l'option View job (Voir la tâche) pour afficher la tâche dans l'éditeur visuel.
- Sélectionnez le menu Actions, puis l'option Stop run (Arrêter l'exécution) pour arrêter l'exécution de la tâche en cours.
- Cliquez sur le bouton Afficher CloudWatch les journaux pour afficher les journaux d'exécution du travail correspondant à ce travail.
- Choisissez Afficher les détails pour afficher la page des détails de l'exécution de la tâche.

Afficher les journaux d'exécution de la tâche

Vous pouvez afficher les journaux des tâches de diverses manières :

- Sur la page Surveillance, dans le tableau Exécutions de tâches, choisissez une exécution de tâche, puis choisissez Afficher CloudWatch les journaux.
- Dans l'éditeur de tâches visuel, dans l'onglet Runs (Exécutions) d'une tâche, sélectionnez les liens hypertextes pour afficher les journaux :
 - Logs (Journaux) Liens vers les journaux de tâche Apache Spark écrits lorsque la journalisation continue est activée pour une exécution de tâche. Lorsque vous cliquez sur ce lien, vous accédez aux Amazon CloudWatch journaux du groupe de `/aws-glue/jobs/logs-v2` journaux. Par défaut, les journaux excluent les messages non utiles de Apache Hadoop YARN heartbeat et du pilote ou de l'exécuteur Apache Spark. Pour plus d'informations sur la journalisation continue, voir Journalisation [continue pour AWS Glue Emplois](#) dans le AWS Glue Guide du développeur.
 - Error logs (Journaux d'erreur) — Liens vers les journaux écrits dans `stderr` pour cette exécution de tâche. Lorsque vous sélectionnez ce lien, vous accédez aux journaux Amazon CloudWatch dans le groupe de journalisation `/aws-glue/jobs/error`. Vous pouvez utiliser ces journaux pour afficher les détails de toutes les erreurs rencontrées pendant l'exécution de la tâche.
 - Output logs (Journaux de sortie) — Liens vers les journaux écrits dans `stdout` pour cette exécution de tâche. Lorsque vous sélectionnez ce lien, vous accédez aux journaux Amazon CloudWatch dans le groupe de journalisation `/aws-glue/jobs/output`. Vous pouvez utiliser

ces journaux pour voir tous les détails concernant les tables créées dans AWS Glue Data Catalog et toutes les erreurs qui ont été rencontrées.

Affichage des détails d'une exécution de tâche

Vous pouvez choisir une tâche dans la liste Job runs (Exécutions de tâche) sur la page Monitoring (Surveillance), puis choisir View run details (Afficher les détails de l'exécution) pour afficher des informations détaillées sur cette exécution de tâche.

Les informations affichées sur la page de détails de l'exécution de la tâche comprennent :

Propriété	Description
Nom de la tâche	Nom de la tâche .
Statut de l'exécution	État actuel de l'exécution de tâche. Les valeurs peuvent être : • STARTING • RUNNING • STOPPING • STOPPED • SUCCEEDED • FAILED • TIMEOUT
Version Glue	Le AWS Glue version utilisée par le job exécuté.
Tentative récente	Le nombre de tentatives automatiques de relance pour cette exécution de tâche.
L'heure de début	Date et heure auxquelles cette exécution de tâche a démarré.
L'heure de fin	Date et heure auxquelles cette exécution de tâche s'est terminée.

Propriété	Description
L'heure de début	Le temps consacré à la préparation de la tâche.
Durée d'exécution	Le temps consacré à l'exécution du script de tâche.
Nom du déclencheur	Le nom du déclencheur associé à la tâche.
L'heure de dernière modification	La date de dernière modification de la tâche.
Configuration de la sécurité	La configuration de sécurité de la tâche, qui inclut le chiffrement Amazon S3, le chiffrement et les paramètres de CloudWatch chiffrement des signets de tâches.
Expiration	La valeur seuil du délai d'exécution de la tâche.
Capacité allouée	Le nombre de AWS Glue unités de traitement de données (DPUs) allouées pour cette exécution de tâche. Pour plus d'informations sur la planification des capacités, consultez la section Surveillance de la planification de la capacité du DPU dans AWS Glue Guide du développeur.
Capacité max.	Capacité maximale disponible pour l'exécution de la tâche.
Nombre d'employés	Le nombre de travailleurs utilisés pour l'exécution de la tâche.

Propriété	Description
Type d'employé	Type d'employés prédéfinis alloués à l'exécution de la tâche. Les valeurs peuvent être <code>G.1X</code> ou <code>G.2X</code>. • G.1X – Lorsque vous choisissez ce type, vous devez également fournir une valeur pour Number of workers (Nombre d'employés). Chaque travailleur est mappé à 1 DPU (4 VCPUs, 16 Go de mémoire, 64 Go de disque) et fournit 1 exécuter par travailleur. Nous vous recommandons ce type d'employé pour les tâches utilisant beaucoup de mémoire. Il s'agit du type de travailleur par défaut pour AWS Glue Tâches en version 2.0 ou ultérieure. • G.2X – Lorsque vous choisissez ce type, vous devez également fournir une valeur pour Number of workers (Nombre d'employés). Chaque worker correspond à 2 DPUs (8 vCPUs, 32 Go de mémoire, 128 Go de disque) et fournit 1 exécuter par worker. Nous vous recommandons ce type d'employé pour des tâches qui requiert beaucoup de mémoire et des tâches qui effectuent des transformations Machine Learning.
Journaux	Un lien vers les journaux de tâches pour la journalisation continue (<code>/aws-glue/jobs/logs-v2</code>).
Journaux de sortie	Un lien vers les fichiers journaux de sortie de la tâche (<code>/aws-glue/jobs/output</code>).

Propriété	Description
Journaux des erreurs	Un lien vers les fichiers de journalisation des erreurs de la tâche (/aws-glue/jobs/error).

Vous pouvez également afficher les éléments supplémentaires suivants, qui sont disponibles lorsque vous affichez les informations relatives aux exécutions de tâches récentes. Pour de plus amples informations, veuillez consulter [the section called “Afficher les informations sur les exécutions de tâche récentes”](#).

- Arguments d'entrée
- Journaux continus
- Métriques : vous pouvez consulter des vues des métriques de base. Pour plus d'informations sur les métriques fournies, consultez [the section called “Afficher Amazon CloudWatch les statistiques relatives à l'exécution d'une tâche Spark”](#).
- Interface utilisateur Spark : vous pouvez visualiser les journaux Spark relatifs à votre tâche dans l'interface utilisateur Spark. Pour plus d'informations sur l'utilisation de l'interface utilisateur web Spark, consultez [the section called “Surveillance à l'aide de l'interface utilisateur Spark”](#). Activez cette fonctionnalité en suivant la procédure présentée dans [the section called “Activation de l'interface utilisateur Spark pour des tâches”](#).

Afficher Amazon CloudWatch les statistiques relatives à l'exécution d'une tâche Spark

Sur la page de détails d'une exécution de tâche, sous la section Détails de l'exécution, vous pouvez consulter les statistiques de la tâche. AWS Glue Studio envoie des métriques de tâche Amazon CloudWatch pour chaque exécution de tâche.

AWS Glue rapporte les métriques Amazon CloudWatch toutes les 30 secondes. Les métriques AWS Glue représentent des valeurs delta des valeurs précédemment rapportées. Le cas échéant, les tableaux de bord de métriques regroupent (additionnent) les valeurs de plages de 30 secondes pour obtenir une valeur pour la totalité de la dernière minute. Toutefois, les métriques d'Apache AWS Glue Spark transmises à Amazon CloudWatch sont généralement des valeurs absolues qui représentent l'état actuel au moment où elles sont signalées.

 Note

Vous devez configurer votre compte pour accéder à Amazon CloudWatch,.

Les métriques fournissent des informations sur votre exécution de tâche, telles que :

- ETL Data Movement (Mouvement de données ETL) — Nombre d'octets lus ou écrits dans Amazon S3.
- Memory Profile: Heap used (Profil de la mémoire : tas utilisé) — Le nombre d'octets de mémoire utilisés par le tas de la machine virtuelle Java (JVM).
- Memory Profile: heap usage (Profil mémoire : utilisation du tas) — La fraction de la mémoire (échelle : 0-1), indiquée en pourcentage, utilisée par le tas de la JVM.
- CPU Load (Charge CPU) — La fraction de la charge du système CPU utilisée (échelle : 0-1), indiquée en pourcentage.

Afficher Amazon CloudWatch les statistiques relatives à l'exécution d'une tâche Ray

Sur la page de détails d'une exécution de tâche, sous la section Détails de l'exécution, vous pouvez consulter les statistiques de la tâche. AWS Glue Studio envoie des métriques de tâche Amazon CloudWatch pour chaque exécution de tâche.

AWS Glue rapporte les métriques Amazon CloudWatch toutes les 30 secondes. Les métriques AWS Glue représentent des valeurs delta des valeurs précédemment rapportées. Le cas échéant, les tableaux de bord de métriques regroupent (additionnent) les valeurs de plages de 30 secondes pour obtenir une valeur pour la totalité de la dernière minute. Toutefois, les métriques d'Apache AWS Glue Spark transmises à Amazon CloudWatch sont généralement des valeurs absolues qui représentent l'état actuel au moment où elles sont signalées.

 Note

Vous devez configurer votre compte pour y accéder Amazon CloudWatch, comme décrit dans.

Dans tâches Ray, vous pouvez afficher les graphiques de métriques agrégés suivants. Vous pouvez ainsi créer un profil de votre cluster et de vos tâches, ainsi qu'accéder à des informations détaillées sur chaque nœud. Les données des séries chronologiques qui soutiennent ces graphiques sont disponibles CloudWatch pour une analyse plus approfondie.

Profil de tâche : statut de la tâche

Indique le nombre de tâches Ray dans le système. Chaque cycle de vie d'une tâche se voit attribuer sa propre série temporelle.

Profil de tâche : nom de la tâche

Indique le nombre de tâches Ray dans le système. Seules les tâches en attente et actives sont affichées. Chaque type de tâche (par son nom) se voit attribuer sa propre série temporelle.

Profil du cluster : CPUs en cours d'utilisation

Indique le nombre de cœurs de processeur utilisés. Chaque nœud se voit attribuer sa propre série temporelle. Les nœuds sont identifiés par des adresses IP, qui sont éphémères et ne servent qu'à l'identification.

Profil du cluster : utilisation de la mémoire du magasin d'objets

Indique l'utilisation de la mémoire par le cache d'objets Ray. Chaque emplacement de mémoire (mémoire physique, mémoire mise en cache sur disque et déversée dans Amazon S3) reçoit sa propre série temporelle. Le magasin d'objets gère le stockage de données sur tous les nœuds du cluster. Pour en savoir plus, consultez [Objects](#) dans la documentation Ray.

Profil du cluster : nombre de nœuds

Affiche le nombre de nœuds provisionnés pour le cluster.

Détail du nœud : utilisation du processeur

Affiche l'utilisation du processeur sur chaque nœud sous forme de pourcentage. Chaque série affiche un pourcentage agrégé de l'utilisation du processeur sur tous les cœurs du nœud.

Détail du nœud : utilisation de la mémoire

Affiche l'utilisation de la mémoire sur chaque nœud en Go. Chaque série montre la mémoire agrégée entre tous les processus du nœud, y compris les tâches Ray et le processus de stockage Plasma. Cela ne reflète pas les objets stockés sur le disque ou déversés sur Amazon S3.

Détail du nœud : utilisation du disque

Affiche l'utilisation du disque sur chaque nœud en Go.

Détail du nœud : vitesse d'E/S du disque

Affiche les E/S du disque sur chaque nœud en Ko/s.

Détail du nœud : débit d'E/S du réseau

Affiche les E/S du réseau sur chaque nœud en Ko/s.

Détail du nœud : utilisation du processeur par le composant Ray

Affiche l'utilisation du processeur dans fractions d'un cœur. Chaque composant Ray sur chaque nœud se voit attribuer sa propre série temporelle.

Détail du nœud : utilisation de la mémoire par le composant Ray

Affiche l'utilisation de la mémoire en Gio. Chaque composant Ray sur chaque nœud se voit attribuer sa propre série temporelle.

Détecter et traiter les données sensibles

La transformation Detect PII identifie les informations personnelles identifiables (PII) dans votre source de données. Vous choisissez l'entité PII à identifier, la manière dont vous voulez que les données soient analysées et ce qui doit être fait avec l'entité PII qui a été identifiée par la transformation Detect PII.

La transformation Détecter les PII permet de détecter, masquer ou supprimer des entités que vous définissez ou qui sont prédéfinies par AWS. Cela vous permet d'accroître la conformité et de réduire la responsabilité. Par exemple, vous voudrez peut-être vous assurer qu'aucune information personnelle ne peut être lue dans vos données et masquer les numéros de sécurité sociale avec une chaîne fixe (telle que xxx-xx-xxxx), des numéros de téléphone ou des adresses.

Pour travailler avec des données sensibles en dehors de AWS Glue Studio, voir [Utilisation de la détection des données sensibles en dehors de AWS Glue Studio](#)

Rubriques

- [Choix du mode d'analyse des données](#)
- [Choix des entités PII à détecter](#)
- [Spécification du niveau de sensibilité de détection](#)
- [Choix de ce qu'il faut faire avec les données PII identifiées](#)
- [Ajout des remplacements précis des actions](#)

Choix du mode d'analyse des données

Lorsque vous analysez votre jeu de données à la recherche de données sensibles telles que des données d'identification personnelle (PII), vous pouvez choisir de détecter les données d'identification personnelle dans chaque ligne ou de détecter les colonnes contenant des données d'identification personnelle.

☐ **Detect PII in each cell**
Scan the entire data set, and act on each occurrence individually.

☒ **Detect fields containing PII**
To reduce costs and improve performance, sample only a portion of the data and act on fields across all records.

Sample portion
The percentage of rows to sample out of the entire data set.
 %
Between 1 and 100.

Detection threshold
To consider a field as containing PII, set the minimum percentage of detected rows out of the sampled rows.
 %
Between 1 and 100.

Lorsque vous choisissez Detect PII in each cell (Détectez les PII dans chaque cellule), vous choisissez d'analyser toutes les lignes de la source de données. Il s'agit d'une analyse complète qui permet de s'assurer que les entités PII sont identifiées.

Lorsque vous choisissez Detect fields containing PII (Détecter les champs contenant des informations personnelles identifiables), vous choisissez d'analyser un échantillon de lignes à la recherche d'entités PII. Il s'agit d'un moyen de réduire les coûts et les ressources tout en identifiant les champs dans lesquels les entités PII sont trouvées.

Lorsque vous choisissez de détecter des champs contenant des informations personnelles, vous pouvez réduire les coûts et améliorer les performances en échantillonnant une partie de lignes. Le choix de cette option vous permettra de spécifier des options supplémentaires :

- **Portion d'échantillon** : vous permet de spécifier le pourcentage de lignes à échantillonner. Par exemple, si vous saisissez « 50 », vous spécifiez que vous voulez que 50 % des lignes soient analysées pour l'entité PII.

- **Seuil de détection** : vous permet de préciser le pourcentage de lignes contenant l'entité PII afin que la colonne entière soit identifiée comme ayant l'entité PII. Par exemple, si vous saisissez le nombre « 10 », vous spécifiez que le numéro de l'entité PII, US Phone, dans les lignes analysées doit être égal ou supérieur à 10 % pour que le champ soit identifié comme ayant l'entité PII, US Phone. Si le pourcentage de lignes contenant l'entité PII est inférieur à 10 %, ce champ ne sera pas étiqueté comme comportant l'entité PII, US Phone, dans celui-ci.

Choix des entités PII à détecter

Si vous avez choisi Detect PII in each cell (Déterminez les PII dans chaque cellule), vous pouvez choisir parmi trois options :

- Tous les modèles d'informations personnelles disponibles, y compris AWS les entités.
- Sélectionnez des catégories : les modèles PII incluent automatiquement des modèles dans les catégories que vous sélectionnez.
- Sélectionnez des modèles spécifiques : seuls les modèles que vous sélectionnez seront détectés.

Pour afficher la liste complète des types de données sensibles gérés, consultez [Managed data types](#).

Choisir parmi tous les modèles PII disponibles

Si vous sélectionnez Tous les modèles d'informations personnelles disponibles, sélectionnez les entités prédéfinies par AWS. Vous pouvez sélectionner une, plusieurs ou toutes les entités.

Select entities to detect



Available entities (19)



Select all

Clear all

Create new

Manage

Find entities

All categories ▼

< 1 >

☐	Entity name ▼	Category ▲
☐	Person's name	Universal, HIPAA
☐	Email (General)	Universal
☐	Credit Card	Universal
☐	IP Address	Networking
☐	MAC Address	Networking
☐	US Phone	United States, HIPAA
☐	US Passport	United States
☐	Social Security Number (SSN)	United States, HIPAA
☐	US Individual Taxpayer Identification Number (ITIN)	United States, HIPAA
☐	US/Canada bank account	United States, HIPAA
☐	US driving license	HIPAA
☐	Healthcare Common Procedure Coding System (HCPCS) code	HIPAA
☐	National Drug Code (NDC)	HIPAA
☐	National Provider Identifier (NPI)	HIPAA
☐	Drug Enforcement Agency (DEA) Registration Number	HIPAA
☐	Health Insurance Claim Number (HICN)	HIPAA
☐	Medicare Beneficiary Identifier	HIPAA

Sélectionner des catégories

Si vous avez choisi `Select categories` (Sélectionner des catégories) comme les modèles PII à détecter, vous pouvez sélectionner les options du menu déroulant. Notez que certaines entités peuvent appartenir à plusieurs catégories. Par exemple, `Nom de la personne` est une entité appartenant aux catégories `Universel` et `HIPAA`.

- `Universel` (exemples : e-mail, carte de crédit)
- `HIPAA` (exemples : permis de conduire américain, code du Healthcare Common Procedure Coding System (HCPCS))
- `Réseaux` (exemples : adresse IP, adresse MAC)
- `Argentine`
- `Australie`
- `Autriche`
- `Belgique`
- `Bosnie`
- `Bulgarie`
- `Canada`
- `Chili`
- `Colombie`
- `Croatie`
- `Chypre`
- `Tchéquie`
- `Danemark`
- `Estonie`
- `Finlande`
- `France`
- `Allemagne`
- `Grèce`
- `Hongrie`
- `Irlande`
- `Corée`

- Japon
- Mexique
- Pays-Bas
- Nouvelle-Zélande
- Norvège
- Portugal
- Roumanie
- Singapour
- Slovaquie
- Slovénie
- Espagne
- Suède
- Suisse
- Turquie
- Ukraine
- États-Unis
- Royaume-Uni
- Venezuela

Sélectionner des modèles spécifiques

Si vous choisissez **Select specific patterns** (Sélectionner des modèles spécifiques) en tant que modèles PII à détecter, vous pouvez rechercher ou parcourir une liste de modèles que vous avez déjà créés, ou créer un modèle d'entité de détection.

Les étapes ci-dessous décrivent comment créer un nouveau modèle personnalisé pour détecter des données sensibles. Vous allez créer le modèle personnalisé en saisissant un nom pour le modèle personnalisé, en ajoutant une expression régulière et, éventuellement, en définissant des mots contextuels.

1. Pour créer un modèle, cliquez sur le bouton **Créer un nouveau**

Select patterns



search patterns by name, or browse to select

Browse

Create new

2. Dans la page Créer une entité de détection, saisissez le nom de l'entité et une expression régulière. L'expression régulière (Regex) est ce que AWS Glue sera utilisé pour faire correspondre les entités.
3. Cliquez sur Valider. Si la validation est réussie, un message de confirmation s'affiche indiquant que la chaîne est une expression régulière valide. Si la validation échoue, vous verrez un message indiquant que la chaîne n'est pas conforme au formatage approprié et aux littéraux de caractères, aux opérateurs ou aux constructions acceptés.
4. Vous pouvez choisir d'ajouter des mots contextuels en plus de l'expression régulière. Les mots contextuels peuvent augmenter la probabilité d'une correspondance. Ils peuvent être utiles dans les cas où les noms des champs ne sont pas descriptifs de l'entité. Par exemple, les numéros de sécurité sociale peuvent être nommés « SSN » ou « SS ». L'ajout de ces mots contextuels peut aider à faire correspondre l'entité.
5. Cliquez sur Créer pour créer l'entité de détection. Toutes les entités créées sont visibles dans AWS Glue Studio console. Cliquez sur Detection entities (Entités de détection) dans le menu de navigation de gauche.

Vous pouvez modifier, supprimer ou créer des entités de détection depuis la page Entités de détection. Vous pouvez également rechercher un modèle à l'aide du champ de recherche.

Spécification du niveau de sensibilité de détection

Vous pouvez définir le niveau de sensibilité lorsque vous utilisez la détection de données sensibles.

- Élevé : (par défaut) détecte un plus grand nombre d'entités pour les cas d'utilisation nécessitant un niveau de sensibilité plus élevé. Tous AWS Glue les emplois créés après novembre 2023 sont automatiquement activés dans ce paramètre.
- Faible : détecte moins d'entités et réduit le nombre de faux positifs.

Select global detection sensitivity

Choose the level of detection sensitivity to apply to your data set.

- ☒ **High (default)**
Detects more entities for use cases that require a higher level of sensitivity.
- ☐ **Low**
Detects fewer entities and reduces false positives.

Choix de ce qu'il faut faire avec les données PII identifiées

Si vous avez choisi de détecter les PII dans l'ensemble de la source de données, vous pouvez sélectionner une action globale à appliquer :

- Enrichir les données avec des résultats de détection : Si vous avez choisi de détecter les PII dans chaque cellule, vous pouvez stocker les entités détectées dans une nouvelle colonne.
- Remplacer le texte détecté : Vous pouvez remplacer la valeur de PII détectée par une chaîne que vous spécifiez dans le champ de saisie Remplacement de texte facultatif. Si aucune chaîne n'est spécifiée, l'entité PII détectée est remplacée par '*****'.
- Censurer partiellement le texte détecté : vous pouvez remplacer une partie de la valeur PII détectée par une chaîne de votre choix. Deux options sont possibles : soit laisser les extrémités non masquées, soit les masquer en fournissant un modèle régulier explicite. Cette fonctionnalité n'est pas disponible dans AWS Glue 2.0.
- Appliquer un hachage de chiffrement : vous pouvez transmettre la valeur PII détectée à une fonction de hachage de chiffrement SHA-256 et remplacer la valeur par la sortie de la fonction.

Select global action (required)

Choose an action to take on detected entities.

- ☒ **DETECT. Enrich data with detection results.**
Create a new column that will contain any entity type detected in that row.
- ☐ **REDACT. Redact detected text.**
Replace detected entity with a string you choose.
- ☐ **PARTIAL_REDACT. Partially redact detected text.**
Replace part of a detected entity with a string you choose.
- ☐ **SHA256_HASH. Apply cryptographic hash.**
Apply a SHA-256 cryptographic hash function to the input string.

Différences entre AWS Glue versions 2.0 et 3.0+

AWS Glue Les tâches 2.0 renverront une nouvelle DataFrame avec les informations PII détectées pour chaque colonne dans une colonne supplémentaire. Tout travail de rédaction ou de hachage est visible dans le AWS Glue script dans l'onglet visuel.

AWS Glue Les tâches 3.0 et 4.0 renverront une nouvelle DataFrame avec cette même colonne supplémentaire. Une nouvelle clé pour « actionUsed » est présente et peut être l'une des valeurs DETECT, REDACT, PARTIAL_REDACT ou SHA256_HASH. Si une action de masquage est sélectionnée, les données DataFrame seront renvoyées avec des données sensibles masquées.

Ajout des remplacements précis des actions

Des paramètres de détection et d'action supplémentaires peuvent être ajoutés à la table des remplacements précis des actions. Cela vous permet de :

- Inclure ou exclure certaines colonnes de la détection : un schéma déduit sur la source de données remplira la table avec les colonnes disponibles.
- Spécifier des paramètres spécifiques plus précis qu'en utilisant des actions globales : par exemple, vous pouvez spécifier différents paramètres de texte de censure pour différents types d'entités.
- Spécifier une action différente de l'action globale : si une action différente doit être appliquée à un autre type de données sensibles, vous pouvez le faire ici. Notez que deux edit-in-place actions différentes (rédaction et hachage) ne peuvent pas être utilisées sur la même colonne, mais que la détection peut toujours être utilisée.

Fine grained actions (overrides) (0)

Edit as JSONDeleteEditAdd

Select entities to add a fine grained action different from the global action above.

< 1 >

	Entity type ▲	Action ▼	Action options	Columns
No overrides				

Gérer les tâches ETL avec AWS Glue Studio

Vous pouvez utiliser l'interface graphique simple dans AWS Glue Studio pour gérer vos tâches ETL. Dans le menu de navigation, choisissez Jobs (Tâches) pour afficher la page Jobs (Tâches). Sur cette page, vous pouvez voir tous les emplois que vous avez créés soit avec AWS Glue Studio ou le AWS Glue console. Vous pouvez afficher, gérer et exécuter vos tâches sur cette page.

Cette page vous permet également d'effectuer les actions suivantes :

- [Démarrer une exécution de tâche](#)
- [Planifier des exécutions de tâche](#)
- [Gestion des planifications de tâche](#)
- [Arrêter les exécutions de tâche](#)
- [Voir vos tâches](#)
- [Afficher les informations sur les exécutions de tâche récentes](#)
- [Afficher le script de tâche](#)
- [Modifier les propriétés de tâche](#)
- [Sauvegarder la tâche](#)
- [Cloner une tâche](#)
- [Supprimer une tâche](#)

Démarrer une exécution de tâche

Entrée AWS Glue Studio, vous pouvez exécuter vos tâches à la demande. Une tâche peut être exécutée plusieurs fois, et chaque fois que vous l'exécutez, AWS Glue recueille des informations sur les activités professionnelles et les performances. Cette information est appelée job run (exécution de tâches) et est identifiée par un ID d'exécution de tâche.

Vous pouvez lancer l'exécution d'une tâche de la manière suivante dans AWS Glue Studio:

- Sur la page Jobs (Tâches), choisissez la tâche à démarrer, puis choisissez le bouton Run job (Exécuter une tâche).
- Si vous affichez une tâche dans l'éditeur visuel et que la tâche a été sauvegardée, vous pouvez choisir le bouton Run (Exécuter) pour démarrer une exécution de tâche.

Pour plus d'informations sur les exécutions de tâches, consultez la section [Utilisation des tâches sur le AWS Glue Console](#) dans le guide du AWS Glue développeur.

Planifier des exécutions de tâche

Entrée AWS Glue Studio, vous pouvez créer un calendrier pour exécuter vos tâches à des moments précis. Vous pouvez spécifier des contraintes, telles que le nombre d'exécutions des tâches, les jours de la semaine où elles sont exécutées et l'heure à laquelle elles le sont. Ces contraintes sont basées sur `cron` et possèdent les mêmes limitations que `cron`. Par exemple, si vous choisissez d'exécuter votre tâche le 31 de chaque mois, n'oubliez pas que certains mois ne comportent pas 31 jours. Pour plus d'informations sur `cron`, veuillez consulter la rubrique [Cron expressions](#) dans le Guide du développeur AWS Glue .

Pour exécuter des tâches selon une planification

1. Créez une planification de tâche à l'aide d'une des méthodes suivantes :
 - Sur la page Jobs (Tâches), choisissez la tâche pour laquelle vous voulez créer une planification, choisissez Actions, puis choisissez Schedule job (Planification de tâches).
 - Si vous visualisez une tâche dans l'éditeur visuel et que cette tâche a été enregistrée, choisissez l'onglet Schedules (Planifications). Puis choisissez Create Schedule (Créer une planification).
2. Sur la pageSchedule job run (Planification des exécutions de tâches), saisissez les informations suivantes :
 - Name (Nom) : saisissez un nom pour votre planification de tâche.
 - Frequency (Fréquence) : entrez la fréquence de la planification de tâche. Vous pouvez choisir parmi les options suivantes :
 - Hourly (Horaire) : la tâche s'exécutera toutes les heures, à partir d'une minute spécifique. Vous pouvez spécifier la Minute de l'heure à laquelle la tâche doit être exécutée. Par défaut, lorsque vous choisissez horaire, la tâche s'exécute au début de l'heure (minute 0).
 - Daily (Journalier) : La tâche s'exécutera tous les jours, en commençant à un moment donné. Vous pouvez spécifier les valeurs de Minute et Start hour (Heure de début) pour définir l'heure à laquelle la tâche s'exécutera. Les heures sont spécifiées à l'aide d'une horloge de 23 heures, où vous utilisez les chiffres 13 à 23 pour les heures de l'après-midi. Les valeurs par défaut pour les minutes et les heures sont 0, ce qui signifie que si vous sélectionnez Daily (Journalier), la tâche s'exécutera par défaut à minuit.

- **Weekly (Hebdomadaire)** : la tâche s'exécute chaque semaine, un ou plusieurs jours. En plus des mêmes paramètres décrits précédemment pour Daily, vous pouvez choisir les jours de la semaine où la tâche sera exécutée. Vous pouvez choisir un ou plusieurs jours.
- **Monthly (Mensuel)** : la tâche s'exécute tous les mois à un jour précis. En plus des mêmes paramètres que ceux décrits précédemment pour Daily, vous pouvez choisir le jour du mois où la tâche sera exécutée. Spécifiez le jour sous la forme d'une valeur numérique comprise entre 1 et 31. Si vous sélectionnez un jour qui n'existe pas au cours d'un mois, par exemple le 30^e jour de février, la tâche ne sera pas exécutée ce mois-là.
- **Custom (Personnalisée)** : entrez une expression pour votre planification de tâche à l'aide de la syntaxe cron. Les expressions Cron vous permettent de créer des planifications plus complexes, telles que le dernier jour du mois (au lieu d'un jour spécifique du mois) ou tous les trois mois, les 7^e et 21^e jours du mois.

Veillez consulter la rubrique [Expressions cron](#) dans le Guide du développeur AWS Glue

- **Description** : vous pouvez éventuellement saisir une description pour votre planification de tâche. Si vous envisagez d'utiliser la même planification pour plusieurs tâches, la description vous permet de déterminer plus facilement l'action de la planification.
3. Choisissez **Create schedule** (Créer une planification) pour enregistrer la planification de la tâche.
 4. Une fois que vous avez créé la planification, un message de réussite s'affiche en haut de la page de la console. Vous pouvez choisir **Job details** (Détails de la tâche) dans cette bannière pour afficher les détails de la tâche. Cela ouvre la page de l'éditeur de tâches visuel, avec l'onglet **Schedules** (Planifications) sélectionné.

Gestion des planifications de tâche

Une fois que vous avez créé des planifications pour une tâche, vous pouvez l'ouvrir dans l'éditeur visuel et choisir l'onglet **Schedules** (Planifications) pour gérer les planifications.

Sur la page **Schedules** (Planifications) de l'éditeur visuel, vous pouvez effectuer les tâches suivantes :

- Créer une planification.

Choisissez **Create schedule** (Création de planification), puis entrez les informations de votre planification comme décrit dans [the section called “Planifier des exécutions de tâche”](#).

- Modifier une planification existante.

Choisissez la planification à modifier, puis choisissez Action suivi de Edit schedule (Modifier une planification). Lorsque vous choisissez de modifier une planification existante, la Frequency (Fréquence) s'affiche comme Custom (Personnalisée), et la planification s'affiche comme une expression cron. Vous pouvez modifier l'expression cron, ou spécifier une nouvelle planification à l'aide du bouton Frequency (Fréquence). Lorsque vous avez terminé vos modifications, choisissez Update schedule (Mettre à jour la planification).

- Suspendre une planification active.

Choisissez une planification active, puis choisissez Action suivi de Pause schedule (Suspendre la planification). La planification est désactivée instantanément. Choisissez le bouton d'actualisation (rechargement) pour consulter l'état actualisé de la planification de tâche.

- Reprendre une planification suspendue.

Choisissez une planification inactive, puis choisissez Action suivi de Resume schedule (Reprendre la planification). La planification est activée instantanément. Choisissez le bouton d'actualisation (rechargement) pour consulter l'état actualisé de la planification de tâche.

- Supprimer une planification.

Choisissez la planification à supprimer, puis choisissez Action suivi de Delete schedule (Supprimer une planification). La planification est supprimée instantanément. Choisissez le bouton d'actualisation (rechargement) pour consulter la liste actualisée de planification de tâche. La planification affichera un état Deleting (Suppression) jusqu'à ce qu'elle ait été complètement supprimée.

Arrêter les exécutions de tâche

Vous pouvez arrêter une tâche avant qu'elle n'ait terminé son exécution. Vous pouvez choisir cette option si vous savez que la tâche n'est pas configurée correctement ou si la tâche prend trop de temps à s'exécuter.

Sur la page Monitoring (Surveillance), dans la liste Job runs (Exécutions de tâche), choisissez la tâche que vous souhaitez arrêter, choisissez Actions, puis choisissez Stop run (Arrêter l'exécution).

Voir vos tâches

Vous pouvez afficher toutes vos tâches sur la page Jobs (Tâches). Vous pouvez accéder à cette page en choisissant Jobs (Tâches) dans le panneau de navigation.

Sur la page Jobs (Tâches), vous pouvez voir toutes les tâches qui ont été créées dans votre compte. La liste Your jobs (Vos tâches) affiche le nom de la tâche, son type, le statut de la dernière exécution de cette tâche, ainsi que les dates de création et de dernière modification de la tâche. Vous pouvez choisir le nom d'une tâche pour afficher des informations détaillées sur celle-ci.

Vous pouvez également utiliser le tableau de bord Surveillance pour afficher toutes vos tâches. Vous pouvez accéder au tableau de bord en sélectionnant Monitoring (Surveillance) dans le panneau de navigation.

Personnalisation de l'affichage des tâches

Vous pouvez personnaliser la façon dont les tâches sont affichées dans la section Your jobs (Vos tâches) de la page Jobs (Tâches). En outre, vous pouvez saisir du texte dans le champ de recherche pour afficher uniquement les tâches dont le nom contient ce texte.

Si vous choisissez l'icône des paramètres



dans la section Vos tâches, vous pouvez personnaliser la façon dont AWS Glue Studio affiche les informations du tableau. Vous pouvez choisir de regrouper les lignes de texte dans l'affichage, de modifier le nombre de tâches affichées sur la page et de spécifier les colonnes à afficher.

Afficher les informations sur les exécutions de tâche récentes

Une tâche peut être exécutée plusieurs fois à mesure que de nouvelles données sont ajoutées à l'emplacement source. Chaque fois qu'une tâche s'exécute, un ID unique lui est attribué et des informations sur cette exécution sont collectées. Vous pouvez consulter ces informations en utilisant les méthodes suivantes :

- Choisissez l'onglet Runs (Exécutions) de l'éditeur visuel pour afficher les informations d'exécution de la tâche actuellement affichée.

Sur l'onglet Runs (Exécutions) (la page Recent job runs (Exécutions de tâche récentes)), il y a une carte pour chaque exécution de tâche. Les informations affichées sur l'onglet Runs (Exécutions) comprennent :

- ID d'exécution de la tâche
- Nombre de tentatives d'exécution de cette tâche
- Statut de l'exécution de la tâche
- Heure de début et de fin de l'exécution de la tâche

- Le moteur d'exécution de la tâche
 - Un lien vers les fichiers du journal de tâche
 - Un lien vers les fichiers de journalisation des erreurs de tâche
 - L'erreur renvoyée pour les tâches ayant échoué
- Vous pouvez sélectionner une tâche pour afficher des informations supplémentaires sur celle-ci, notamment :
- Arguments d'entrée
 - Journaux continus
 - Métriques : vous pouvez consulter des vues des métriques de base. Pour plus d'informations sur les métriques fournies, consultez [the section called “Afficher Amazon CloudWatch les statistiques relatives à l'exécution d'une tâche Spark”](#).
 - Interface utilisateur Spark : vous pouvez visualiser les journaux Spark relatifs à votre tâche dans l'interface utilisateur Spark. Pour plus d'informations sur l'utilisation de l'interface utilisateur web Spark, consultez [the section called “Surveillance à l'aide de l'interface utilisateur Spark”](#). Activez cette fonctionnalité en suivant la procédure présentée dans [the section called “Activation de l'interface utilisateur Spark pour des tâches”](#).

Vous pouvez sélectionner Afficher les détails pour afficher des informations similaires sur la page des détails de l'exécution de la tâche. Vous pouvez également accéder à la page des détails de l'exécution de la tâche via la page Surveillance. Dans le panneau de navigation, choisissez Surveillance. Faites défiler jusqu'à la liste Job runs (Exécutions de tâche). Choisissez la tâche, puis choisissez View run details (Afficher les détails de l'exécution). Le contenu est décrit dans [Affichage des détails d'une exécution de tâche](#).

Pour plus d'informations sur les valeurs de tâche, veuillez consulter [Afficher les journaux d'exécution de la tâche](#).

Afficher le script de tâche

Après avoir fourni des informations pour tous les nœuds de la tâche, AWS Glue Studio génère un script qui est utilisé par la tâche pour lire les données depuis la source, les transformer et les écrire dans l'emplacement cible. Si vous sauvegardez la tâche, vous pouvez afficher ce script à tout moment.

Pour afficher le script généré pour votre tâche

1. Dans le panneau de navigation, sélectionnez Jobs (Tâches).
2. Sur la page Jobs (Tâches), dans la liste our jobs (Vos tâches), choisissez le nom de la tâche que vous souhaitez vérifier. Vous pouvez également sélectionner une tâche dans la liste, choisir le menu Actions, puis choisir Edit job (Modifier une tâche).
3. Sur la page de l'éditeur visuel, choisissez l'onglet Script en haut pour afficher le script de tâche.

Si vous souhaitez modifier le script de tâche, veuillez consulter [AWS Glue guide de programmation](#).

Modifier les propriétés de tâche

Les nœuds du diagramme de tâche définissent les actions effectuées par la tâche, mais il existe également plusieurs propriétés que vous pouvez configurer pour la tâche. Ces propriétés déterminent l'environnement dans lequel la tâche s'exécute, les ressources qu'elle utilise, les paramètres de seuil, les paramètres de sécurité, etc.

Pour personnaliser l'environnement d'exécution de la tâche

1. Dans le panneau de navigation, sélectionnez Jobs (Tâches).
2. Sur la page Jobs (Tâches), dans la liste our jobs (Vos tâches), choisissez le nom de la tâche que vous souhaitez vérifier.
3. Sur la page de l'éditeur visuel, choisissez l'onglet Job details (Détails de la tâche) en haut du volet de modification des tâches.
4. Modifiez les propriétés de la tâche, si nécessaire.

Pour plus d'informations sur les propriétés de tâche, veuillez consulter [Définition des propriétés d'une tâche](#) dans le Guide du développeur AWS Glue .

5. Développez la section Advanced properties (Propriétés avancées) si vous devez spécifier les propriétés de tâche supplémentaires suivantes :
- Script filename (Nom du fichier de script) — Le nom du fichier qui stocke le script de tâche dans Amazon S3.
 - Script path (Chemin du script) — L'emplacement Amazon S3 dans lequel le script de tâche est stocké.

- Métriques de tâche — (Non disponible pour les tâches shell Python) Active la création de Amazon CloudWatch métriques lors de l'exécution de cette tâche.
- Journalisation continue — (Non disponible pour les tâches du shell Python) Active la journalisation continue afin que les journaux puissent être consultés avant la fin de la tâche. CloudWatch
- Spark UI (Interface utilisateur Spark) et Spark UI logs path (Chemin des journaux de l'interface utilisateur Spark) — (Non disponible pour les tâches shell Python) Active l'utilisation de l'interface utilisateur Spark pour la surveillance de ce travail et spécifie l'emplacement des journaux de l'interface utilisateur Spark.
- Maximum concurrency (Concurrence maximale) — Définit le nombre maximal d'exécutions simultanées autorisées pour cette tâche.
- Chemin temporaire : emplacement d'un répertoire de travail dans Amazon S3 où les résultats intermédiaires temporaires sont écrits lorsque AWS Glue exécute le script de tâche.
- Delay notification threshold (minutes) (Seuil de notification de délai, en minutes) — Spécifie un seuil de temporisation pour la tâche. Si la durée d'exécution de la tâche est supérieure à celle spécifiée par le seuil, alors AWS Glue envoie une notification de retard pour la tâche à CloudWatch.
- Security configuration (Configuration de la sécurité) et Server-side encryption (Chiffrement côté serveur) — Utilisez ces champs pour choisir les options de chiffrement de la tâche.
- Utiliser le catalogue de données Glue comme métastore Hive — Choisissez cette option si vous souhaitez utiliser le AWS Glue Data Catalog comme alternative à Apache Hive Metastore.
- Additional network connection (Connexion réseau supplémentaire) — Pour une source de données dans un VPC, vous pouvez spécifier une connexion de type Network afin de vous assurer que votre tâche accède à vos données via le VPC.
- Python library path (Chemin de la bibliothèque Python), Dependent jars path (Chemin des fichiers .jar dépendants) (Non disponible pour les tâches shell Python), ou Referenced files path (Chemin de fichiers référencés) — Utilisez ces champs pour spécifier l'emplacement des fichiers supplémentaires utilisés par la tâche lors de l'exécution du script.
- Job Parameters (Paramètres de tâche) — Vous pouvez ajouter un ensemble de paires clé-valeur qui sont transmises comme paramètres nommés au script de tâche. Dans les appels Python à AWS Glue API s, il est préférable de transmettre les paramètres explicitement par leur nom. Pour plus d'informations sur l'utilisation de paramètres dans un script de tâche,

voir [Transmission et accès à des paramètres Python dans AWS Glue](#) dans le Manuel du développeur AWS Glue .

- Tags (Balises) — Vous pouvez ajouter des balises à la tâche pour mieux les organiser et les identifier.

6. Après avoir modifié les propriétés de la tâche, sauvegardez la tâche.

Stocker les fichiers Spark shuffle sur Amazon S3

Certaines tâches ETL nécessitent la lecture et la combinaison d'informations provenant de plusieurs partitions, par exemple lors de l'utilisation d'une transformation de jointure. Cette opération est appelée shuffling (brassage). Lors d'un brassage, les données sont écrites sur le disque et transférées sur le réseau. Avec AWS Glue version 3.0, vous pouvez configurer Amazon S3 comme emplacement de stockage pour ces fichiers. AWS Glue fournit un gestionnaire de shuffle qui écrit et lit des fichiers de shuffle vers et depuis Amazon S3. L'écriture et la lecture de fichiers shuffle depuis Amazon S3 sont plus lentes (de 5 % à 20 %) par rapport au disque local (ou à Amazon EBS, qui est fortement optimisé pour Amazon). Toutefois, Amazon S3 offre une capacité de stockage illimitée, de sorte que vous n'avez pas à vous soucier des erreurs « No space left on device » lors de l'exécution de votre tâche.

Pour configurer votre tâche de manière à utiliser Amazon S3 pour les fichiers de brassage

1. Sur la page Jobs (Tâches), dans la liste our jobs (Vos tâches), choisissez le nom de la tâche que vous souhaitez modifier.
2. Sur la page de l'éditeur visuel, choisissez l'onglet Job details (Détails de la tâche) en haut du volet de modification des tâches.

Faites défiler jusqu'à la section Job parameters (Paramètres de la tâche).

3. Spécifiez les paires clé-valeur suivantes.

- `--write-shuffle-files-to-s3 — true`

Il s'agit du paramètre principal qui configure le gestionnaire de shuffle dans AWS Glue pour utiliser les compartiments Amazon S3 pour écrire et lire des données de shuffle. Par défaut, ce paramètre a une valeur de `false`.

- (Facultatif) `--write-shuffle-spills-to-s3 — true`

Ce paramètre vous permet de télécharger les fichiers de déversement vers des compartiments Amazon S3, ce qui renforce la résilience de votre tâche Spark dans AWS Glue. Cela n'est nécessaire que pour les charges de travail importantes qui déversent de grandes quantités de données sur le disque. Par défaut, ce paramètre a une valeur de `false`.

- (Facultatif) `--conf spark.shuffle.glue.s3ShuffleBucket — S3://<shuffle-bucket>`

Ce paramètre spécifie le compartiment Amazon S3 à utiliser lors de l'écriture des fichiers de brassage. Si vous ne définissez pas ce paramètre, l'emplacement est le dossier `shuffle-data` dans l'emplacement spécifié pour Temporary path (Chemin temporaire) (`--TempDir`).

Note

Assurez-vous que l'emplacement du compartiment shuffle se trouve dans le même emplacement que celui Région AWS dans lequel la tâche s'exécute. En outre, le service de brassage ne nettoie pas les fichiers une fois la tâche terminée. Vous devez donc configurer les stratégies de cycle de vie de stockage Amazon S3 sur l'emplacement du compartiment de brassage. Pour plus d'informations, veuillez consulter [Gestion du cycle de vie des objets](#) dans le Guide de l'utilisateur Amazon S3.

Sauvegarder la tâche

Un rappel rouge Job has not been saved (La tâche n'a pas été sauvegardée) s'affiche à gauche du bouton Save (Enregistrer) jusqu'à ce que vous sauvegardiez la tâche.

Job has not been saved

 Save

Pour sauvegarder votre tâche


1. Fournissez toutes les informations requises dans les onglets Visual (Visuel) et Job details (Détails de la tâche).
2. Choisissez le bouton Enregistrer.

Après avoir enregistré la tâche, le rappel « not saved (non sauvegardée) » change pour afficher l'heure et la date de la dernière sauvegarde de la tâche.

Si tu quittes AWS Glue Studio avant de sauvegarder votre travail, la prochaine fois que vous vous connecterez à AWS Glue Studio, une notification apparaît. La notification indique qu'il existe une tâche non enregistrée et vous demande si vous souhaitez la restaurer. Si vous choisissez de restaurer la tâche, vous pouvez continuer à la modifier.

Résolution des erreurs lors de l'enregistrement d'une tâche

Si vous choisissez le bouton Save (Enregistrer), mais qu'il manque certaines informations requises dans votre tâche, un rappel rouge apparaît sur l'onglet où les informations sont manquantes. Le numéro dans le rappel indique le nombre de champs manquants détectés.



- Si un nœud de l'éditeur visuel n'est pas configuré correctement, l'onglet Visual (Visuel) affiche un rappel rouge et le nœud erroné affiche un symbole d'avertissement .
 1. Choisissez le nœud. Dans le panneau de détails du nœud, un rappel rouge apparaît sur l'onglet où se trouvent les informations manquantes ou incorrectes.
 2. Choisissez l'onglet dans le panneau de détails du nœud qui affiche un rappel rouge, puis recherchez les champs problématiques qui sont mis en évidence. Un message d'erreur sous les champs fournit des informations supplémentaires sur le problème.

Untitled job 

Job has not been saved Save Run

Visual **2** | Script | Job details **1** | Runs | Schedules

Source Transform Target Undo Redo Remove   

Node properties **Data source properties - S3 **2**** 

Output schema

S3 source type [Info](#)

☒ Data Catalog table

☐ S3 location
Choose a file or folder in an S3 bucket.


Database
 

 Database is required.

Table

 Table is required.

Partition predicate - optional
Enter a Boolean expression supported by Spark SQL, using only partition columns.



- S'il y a un problème avec les propriétés de la tâche, l'onglet Job details (Détails de la tâche) affiche un rappel rouge. Choisissez cet onglet et localisez les champs problématiques, qui sont mis en évidence. Les messages d'erreur situés sous les champs fournissent des informations supplémentaires sur le problème.

Untitled job Visual **2** | Script | **Job details 1** | Runs | SchedulesBasic properties [Info](#)

Name

Untitled job

Description - optional

Descriptions can be up to 2048 characters long.

IAM Role

Role assumed by the job with permission to access your data stores. Ensure that this role has permission to your Amazon S3 sources, targets, temporary directory, scripts, and any libraries used by the job.

 IAM Role is required.

Type

The type of ETL job. This is set automatically based on the types of data sources you have selected.

Spark

Cloner une tâche

Vous pouvez utiliser l'action Clone job (Cloner la tâche) pour copier une tâche existante dans une nouvelle tâche.

Pour créer une tâche en copiant une tâche existante

1. Sur la page Jobs (Tâches), dans la liste our jobs (Vos tâches), choisissez la tâche que vous souhaitez dupliquer.
2. Dans le menu Actions, choisissez Clone job (Cloner la tâche).
3. Entrez le nom de la nouvelle tâche. Vous pouvez ensuite enregistrer ou modifier la tâche.

Supprimer une tâche

Vous pouvez supprimer des tâches dont vous n'avez plus besoin. Vous pouvez supprimer une ou plusieurs tâches en une seule opération.

Pour supprimer des tâches de AWS Glue Studio

1. Sur la page Jobs (Tâches), dans la liste our jobs (Vos tâches), choisissez les tâches que vous souhaitez supprimer.
2. Dans le menu Actions, choisissez Delete job (Supprimer la tâche).
3. Vérifiez que vous souhaitez supprimer la tâche en saisissant **delete**.

Vous pouvez également supprimer une tâche enregistrée lorsque vous consultez l'onglet Job details (Détails de la tâche) dans l'éditeur visuel.

Utilisation des tâches dans AWS Glue

Une AWS Glue tâche encapsule un script qui se connecte à vos données source, les traite, puis les écrit dans votre cible de données. En général, une tâche exécute les scripts d'extraction, de transformation et de chargement (ETL). Les tâches peuvent également exécuter des scripts Python à usage général (tâches shell Python). Les déclencheurs AWS Glue peuvent démarrer des tâches en fonction d'une planification, d'un événement ou à la demande. Vous pouvez surveiller les exécutions de tâche pour comprendre les métriques d'exécution telles que le statut d'achèvement, la durée et l'heure de début.

Vous pouvez utiliser des scripts qui AWS Glue génèrent ou vous pouvez fournir les vôtres. Avec un schéma source et un emplacement ou un schéma cible, le générateur de AWS Glue code peut créer automatiquement un script d'API Apache Spark (PySpark). Vous pouvez utiliser ce script comme point de départ et le modifier en fonction de vos objectifs.

AWS Glue peut écrire des fichiers de sortie dans plusieurs formats de données, notamment JSON, CSV, ORC (Optimized Row Columnar), Apache Parquet et Apache Avro. Pour certains formats de données, des formats de compression courants peuvent être écrits.

AWS Glue prend en charge les types d'emplois suivants :

- Une tâche Spark est exécutée dans un environnement Apache Spark géré par AWS Glue. Elle traite les données par lots.
- Une tâche ETL en streaming est similaire à une tâche Spark, sauf qu'elle exécute ETL sur des flux de données. Elle utilise le cadre Apache Spark Structured Streaming. Certaines fonctionnalités de tâche Spark ne sont pas disponibles pour les tâches ETL en streaming.
- Une tâche de shell Python exécute des scripts Python en tant que shell et prend en charge une version de Python qui dépend de la AWS Glue version que vous utilisez. Vous pouvez utiliser ces tâches pour planifier et exécuter des opérations qui ne nécessitent pas un environnement Apache Spark.
- Ray est un framework de calcul distribué open source que vous pouvez utiliser pour augmenter les charges de travail, en mettant l'accent sur Python. AWS Glue Les tâches de Ray et les sessions interactives vous permettent d'utiliser Ray dans Ray AWS Glue.

Les sections suivantes renseignent sur les tâches ETL et Ray dans AWS Glue.

Rubriques

- [AWS Glue versions](#)
- [Utilisation des jobs Spark dans AWS Glue](#)
- [Travailler avec Ray Jobs dans AWS Glue](#)
- [Configuration des propriétés des tâches pour les tâches du shell Python dans AWS Glue](#)
- [Surveillance AWS Glue](#)
- [AWS Glue états d'exécution des tâches](#)

AWS Glue versions

Vous pouvez configurer le paramètre de AWS Glue version lorsque vous ajoutez ou mettez à jour une tâche. La AWS Glue version détermine les versions d'Apache Spark et de Python prises en charge par AWS Glue. La version de Python indique la version qui est prise en charge pour les tâches de type Spark. Le tableau suivant répertorie les versions d' AWS Glue disponibles, les versions Spark et Python correspondantes, ainsi que les autres modifications de fonctionnalité.

AWS Glue versions

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
AWS Glue 5,0	• Spark 3.5.4 • Python 3.11 • Scala 2.12.18	Java 17	Outre les mises à jour du framework, des optimisations et des mises à niveau sont intégrées à cette AWS Glue version, telles que : • Assistance avec Amazon SageMaker Unified Studio • Assistance Amazon SageMaker Lakehouse

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
			• Open Table Formats (OTF) mis à jour vers Hudi 0.15.0, Iceberg 1.7.1 et Delta Lake 3.3.0 • Contrôle d'accès à grain fin natif de Spark à l'aide de Lake Formation. • Assistance relative aux subventions d'accès • requirements.txt prise en charge de l'installation de bibliothèques Python supplémentaires • Support du lignage des données sur Amazon DataZone • Support pour Amazon S3 Table Bucket • AWS Glue Prise en charge de l'affichage en plusieurs dialectes du catalogue de données

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
			Limites Les limites de la AWS Glue version 5.0 sont les suivantes : • Le contrôle d'accès au niveau de la table <code>GlueContext</code> basé sur Glue Dynamic Frame/ avec AWS Lake Formation des autorisations prises en charge dans Glue 4.0 ou antérieur n'est pas pris en charge dans Glue 5.0. Utilisez le nouveau contrôle d'accès fin natif de Spark (FGAC) dans Glue 5.0. Pour plus d'informations sur la migration vers la AWS Glue version 5.0, consultez Migration AWS Glue des tâches Spark vers la AWS Glue version 5.0.

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
AWS Glue 4,0	Versions de l'environnement Spark • Spark 3.3.0 • Python 3.10	Java 8	AWS Glue La version 4.0 intègre un certain nombre d'optimisations et de mises à niveau, telles que : AWS Glue • De nombreuses mises à niveau des fonctionnalités Spark de Spark 3.1 vers Spark 3.3 : • Plusieurs améliorations de fonctionnalités lorsqu'il est associé à Pandas. Pour plus d'informations, consultez Nouveautés de Spark 3.3. • Optimisations supplémentaires développées sur Amazon EMR. • Mise à niveau vers le système de fichiers EMR (EMRFS) 2.53.

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
			• Migration de Log4j 2 à partir de Log4j 1.x • Plusieurs mises à jour de modules Python depuis AWS Glue version 3.0, comme une version de Boto mise à niveau. • Mise à niveau de plusieurs connecteurs, notamment le connecteur Amazon Redshift par défaut. Voir Annexe C : Mises à niveau des connecteurs. • Mise à niveau de plusieurs pilotes JDBC. Voir Annexe B : Mises à niveau du pilote JDBC. • Utilisation d'un nouveau connecteur Amazon Redshift et d'un nouveau pilote JDBC. • Prise en charge native des infrastructures de lac de données ouverts

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
			avec Apache Hudi, Delta Lake et Apache Iceberg. - Prise en charge native du plug-in Cloud Shuffle Storage basé sur Amazon S3 (un plug-in Apache Spark) permettant d'utiliser Amazon S3 pour la réorganisation et la capacité de stockage élastique. Limites Voici les limites de AWS Glue 4.0 : - AWS Glue l'apprentissage automatique et les transformations des informations personnelles identifiables (PII) ne sont pas encore disponibles dans la AWS Glue version 4.0.

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
			Pour plus d'informations sur la migration vers AWS Glue version 4.0, consultez Migration AWS Glue des tâches Spark vers la AWS Glue version 4.0.

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
	Versions de l'environnement Ray Ray 2.4.0 Python 3.9	N/A	Créez et exécutez des applications Python distribuées avec AWS Glue for Ray. - Prend en charge la distribution de données Ray-2.4.0 (<code>ray[data]</code>) avec Python 3.9. Pour plus d'informations sur cette version de Ray, consultez Ray-2.4.0 dans le référentiel Ray. GitHub - Prend en charge l'installation de bibliothèques Python supplémentaires dans l'environnement d'exécution Ray 2.4. Pour de plus amples informations, veuillez consulter the section called “Modules Python supplémentaires pour les tâches Ray”.

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
			• Intègre les journaux et les statistiques de Ray Jobs avec Amazon CloudWatch. Pour plus d'informations, consultez the section called “Dépannage des erreurs Ray” et the section called “Métriques des tâches Ray”. • Regroupe et visualise les métriques des tâches Ray dans AWS Glue Studio, sur la page d'exécution de chaque tâche. • Prend en charge la distribution des fichiers dans chaque répertoire de travail de votre cluster, le déversement d'objets du magasin d'objets Ray vers Amazon S3 et le contrôle du nombre

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
			minimum de composants master alloués à votre tâche Ray. Pour de plus amples informations, veuillez consulter the section called “Paramètres de tâche Ray”. Limitations des tâches Ray dans la version 4.0 de AWS Glue • AWS Glue les sessions interactives pour Ray sont toujours disponibles en avant-première pour cette version. • AWS Glue pour Ray, l'intégration avec Amazon VPC n'est pas disponible actuellement. Les ressources d'un VPC in ne AWS seront pas accessibles sans itinéraire public. Pour plus d'informa

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
			tions sur l'utilisation AWS Glue avec Amazon VPC, consultez. the section called “Configuration des points de terminaux VPC de l'interface () pour AWS PrivateLinkAWS Glue ” • AWS Glue for Ray est disponible dans l'est des États-Unis (Virginie du Nord), dans l'est des États-Unis (Ohio), dans l'ouest des États-Unis (Oregon), en Asie-Pacifique (Tokyo) et en Europe (Irlande).

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
AWS Glue 3,0	• Spark 3.1.1 • Python 3.7	Java 8	En plus de la mise à niveau du moteur Spark vers 3.0, des optimisations et des mises à niveau sont intégrées à cette version de AWS Glue , telles que : • Construit la bibliothèque AWS Glue ETL par rapport à Spark 3.0, qui est une version majeure de Spark. • Les tâches de streaming sont prises en charge sur AWS Glue 3.0. • Inclut de nouvelles optimisations de l'environnement d'exécution de AWS Glue Spark en termes de performances et de fiabilité : • Traitement plus rapide des colonnes en mémoire basé sur Apache Arrow

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
			pour la lecture des données CSV. - Exécution basée sur SIMD pour les lectures vectorisées avec des données CSV. - La mise à niveau Spark inclut également des optimisations supplémentaires développées sur Amazon EMR. - EMRFS mis à niveau de la version 2.38 à 2.46 offrant de nouvelles fonctionnalités et des corrections de bogues pour l'accès à Amazon S3. - Mise à niveau de plusieurs dépendances requises pour la nouvelle version de Spark.

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
			- Pilotes JDBC mis à niveau pour nos sources de données prises en charge en mode natif. Limites Voici les limites de AWS Glue 3.0 : - AWS Glue les transformations du machine learning ne sont pas encore disponibles dans la AWS Glue version 3.0. - Certains connecteurs Spark personnalisés ne fonctionnent pas avec AWS Glue 3.0 s'ils dépendent de Spark 2.4 et ne sont pas compatibles avec Spark 3.1.

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
AWS Glue 2.0 (fin de vie le 1er avril 2026)	• Spark 2.4.3 • Python 3.7	N/A	Outre les fonctionnalités fournies dans la AWS Glue version 1.0, AWS Glue la version 2.0 fournit également : • Une infrastructure améliorée pour exécuter des tâches ETL Apache Spark AWS Glue avec des temps de démarrage réduits. • Désormais, la journalisation par défaut est en temps réel, avec des flux séparés pour les pilotes et les exécuteurs, ainsi que des sorties et des erreurs. • Prise en charge de la spécification de modules Python supplémentaires ou de versions différentes au niveau de la tâche.

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
			 Note AWS Glue la version 2.0 diffère de AWS Glue la version 1.0 pour certaines dépendances et versions en raison de modifications architecturales sous-jacentes. Validez vos tâches AWS Glue avant de migrer vers les versions AWS Glue majeures.

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
AWS Glue 1,0 (fin de vie le 1er avril 2026)	• Spark 2.4.3 • Python 2.7 • Python 3.6	N/A	Vous pouvez gérer les signets de tâche pour les formats Parquet et ORC dans les tâches ETL AWS Glue (avec AWS Glue version 1.0). Auparavant, vous ne pouviez mettre en signet que les formats source courants d'Amazon S3 tels que JSON, CSV, Apache Avro et XML dans les tâches AWS Glue ETL. Lorsque vous définissez les options de format pour les entrées et sorties ETL, vous pouvez spécifier d'utiliser le format de lecture/écriture Apache Avro 1.8 pour prendre en charge la lecture et l'écriture de type logique Avro (à l'aide AWS Glue de la version 1.0). Auparavant, seul le format de lecture/écriture

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
			criture Avro 1.7 était pris en charge. Le type de connexion DynamoDB prend en charge une option d'écriture (à l'aide de AWS Glue version 1.0). Limites Voici les limites de AWS Glue 1.0 : • AWS Glue les versions 0.9 et 1.0 ne seront pas disponibles en Asie-Pacifique (Jakarta) (ap-southeast-3), au Moyen-Orient (Émirats arabes unis) (me-central-1-1) ou dans d'autres nouvelles régions à l'avenir.

AWS Glue version	Versions d'environnement d'exécution prises en charge	Version Java prise en charge	Changements de fonctionnalité
AWS Glue 0,9 (fin de vie le 1er avril 2026)	- Spark 2.2.1 - Python 2.7	N/A	Tâches créées sans spécifier de AWS Glue version par défaut, AWS Glue 0,9. Limites Voici les limites de AWS Glue 0.9 : AWS Glue les versions 0.9 et 1.0 ne seront pas disponibles en Asie-Pacifique (Jakarta) (ap-southeast-3), au Moyen-Orient (Émirats arabes unis) (me-central-1) ou dans d'autres nouvelles régions à l'avenir.

Note

Les versions de Glue suivantes sont compatibles avec les versions suivantes de PythonShell :

- PythonShell La version 3.6 est prise en charge dans la version 1.0 de Glue.
- PythonShell La version 3.9 est prise en charge dans la version 3.0 de Glue.

De plus, les points de terminaison de développement ne sont pris en charge que dans les versions 1.0 et 0.9 de Glue.

AWS Glue politique de support des versions

AWS Glue est un service d'intégration de données sans serveur qui facilite la découverte, la préparation et la combinaison de données pour l'analytique, le machine learning et le développement d'applications. Un AWS Glue la tâche contient la logique métier qui exécute le travail d'intégration des données dans AWS Glue. Il existe trois types d'emplois dans AWS Glue: Spark (batch et streaming), Ray et Python shell. Lorsque vous définissez votre tâche, vous spécifiez AWS Glue version, qui configure les versions dans l'environnement d'exécution Spark, Ray ou Python sous-jacent. Par exemple : un AWS Glue version 5.0 Spark job prend en charge Spark 3.5.4 et Python 3.11.

Politique de prise en charge

AWS Glue les versions sont construites autour d'une combinaison de systèmes d'exploitation, de langages de programmation et de bibliothèques logicielles soumises à des mises à jour de maintenance et de sécurité. AWS Glue la politique de support des versions consiste à mettre fin au support d'une version lorsqu'un composant majeur de la version atteint la fin du support communautaire à long terme (LTS) et que les mises à jour de sécurité ne sont plus disponibles. AWS Glue la politique de support des versions inclut les statuts suivants :

Fin du support (EOS) - Lorsqu'une AWS Glue version atteint EOS :

- AWS Glue n'appliquera plus de correctifs de sécurité ou d'autres mises à jour aux versions d'EOS.
- AWS Glue les offres d'emploi sur les versions EOS ne sont pas éligibles au support technique.
- AWS Glue peut ne pas être honoré SLAs lorsque les tâches sont exécutées sur des versions EOS.

Fin de vie (EOL) - Lorsqu'une AWS Glue version atteint la fin de vie :

- Vous ne pouvez plus créer de nouvelles AWS Glue tâches ni de sessions interactives sur les versions EOL.
- Vous ne pouvez plus démarrer l'exécution de tâches sur ces AWS Glue versions.

- AWS Glue arrêtera les exécutions de tâches existantes et les sessions interactives sur les versions EOL.
- Les versions EOL seront supprimées de AWS Glue SDKs et APIs

Procédez comme suit : AWS Glue les versions ont atteint la fin du support et ne seront plus disponibles après la date de fin de vie. Les modifications du statut de support d'une version commencent à minuit (fuseau horaire du Pacifique) à la date spécifiée.

Type	Version Glue	Fin de l'assistance	Fin de vie
Spark	Glue version 0.9 (Spark 2.2, Scala 2, Python 2)	01/06/2022	01/04/2026
Spark	Glue version 1.0 (Spark 2.4, Python 2)	01/06/2022	01/04/2026
Spark	Glue version 1.0 (Spark 2.4, Scala 2, Python 3)	30/09/2022	01/04/2026
Spark	Glue version 2.0 (Spark 2.4, Python 3)	31/01/2024	01/04/2026
Type	Version Python	Fin de l'assistance	Fin de vie
(shell Python)	Python 2 (Glue Version 1.0)	01/06/2022	01/04/2026
(shell Python)	PythonShell 3.6 (Glue version 1.0)	31/03/2026	NA
Type	Version Notebook	Fin de l'assistance	Fin de vie
Point de terminaison de développement	Zeppelin notebook	30/09/2022	NA

AWS vous recommande vivement de migrer vos tâches vers les versions prises en charge.

Pour plus d'informations sur la migration de vos tâches Spark vers la dernière version AWS Glue version, voir [Migration AWS Glue emplois pour AWS Glue version 5.0](#).

Pour migrer vos jobs shell Python vers la dernière version AWS Glue version :

- Dans la console, choisissez Python 3 (Glue Version 4.0).
- Dans l'[UpdateJobAPI CreateJob/](#), définissez le GlueVersion paramètre sur 2.0 et sur PythonVersion 3 sous le Command paramètre. La GlueVersion configuration n'affecte pas le comportement des tâches shell Python. L'incrémentation GlueVersion ne présente donc aucun avantage.
- Vous devez rendre votre script de tâche compatible avec Python 3.

Migration AWS Glue des tâches Spark vers la AWS Glue version 5.0

Cette rubrique décrit les modifications apportées entre AWS Glue les versions 0.9, 1.0, 2.0, 3.0 et 4.0 pour vous permettre de migrer vos applications Spark et vos tâches ETL vers la AWS Glue version 5.0. Il décrit également les fonctionnalités de la AWS Glue version 5.0 et les avantages de son utilisation.

Pour utiliser cette fonctionnalité avec vos tâches AWS Glue ETL, **5.0** choisissez-la Glue version lors de la création de vos tâches.

Rubriques

- [Nouvelles fonctionnalités](#)
- [Actions pour migrer vers la AWS Glue version 5.0](#)
- [Liste de contrôle de migration](#)
- [AWS Glue Caractéristiques de la version 5.0](#)
- [Migration de la AWS Glue version 4.0 vers AWS Glue la version 5.0](#)
- [Migration de la AWS Glue version 3.0 à AWS Glue la version 5.0](#)
- [Migration de la AWS Glue version 2.0 vers AWS Glue la version 5.0](#)
- [Changements de comportement de journalisation dans la AWS Glue version 5.0](#)
- [Migration du connecteur et du pilote JDBC pour la version 5.0 AWS Glue](#)

Nouvelles fonctionnalités

Cette section décrit les nouvelles fonctionnalités et les avantages de la AWS Glue version 5.0.

- Mise à jour d'Apache Spark de la version 3.3.0 dans la AWS Glue version 4.0 à la version 3.5.4 dans AWS Glue la version 5.0. Consultez [Améliorations majeures de Spark 3.3.0 à Spark 3.5.4](#).
- Contrôle d'accès à grain fin (FGAC) natif de Spark à l'aide de Lake Formation. Cela inclut le FGAC pour les tables Iceberg, Delta et Hudi. Pour plus d'informations, consultez la section [Utilisation AWS Glue avec AWS Lake Formation pour un contrôle d'accès précis](#).

Notez les considérations ou limites suivantes pour le FGAC natif de Spark :

- Actuellement, les écritures de données ne sont pas prises en charge
- Pour écrire dans Iceberg en `GlueContext` utilisant Lake Formation, il faut plutôt utiliser le contrôle d'accès IAM

Pour une liste complète des limites et des considérations relatives à l'utilisation du FGAC natif de Spark, voir. [the section called "Considérations"](#)

- Support des subventions d'accès Amazon S3 en tant que solution de contrôle d'accès évolutive à vos données Amazon S3 depuis AWS Glue. Pour de plus amples informations, veuillez consulter [Utilisation d'Amazon S3 Access Grants avec AWS Glue](#).
- Open Table Formats (OTF) mis à jour vers Hudi 0.15.0, Iceberg 1.7.1 et Delta Lake 3.3.0
- Support d'Amazon SageMaker Unified Studio.
- Amazon SageMaker Lakehouse et intégration de l'abstraction de données. Pour de plus amples informations, veuillez consulter [Interrogation de catalogues de données de métastore à partir de l'ETL AWS Glue](#).
- Support pour installer des bibliothèques Python supplémentaires à l'aide de `requirements.txt`. Pour de plus amples informations, veuillez consulter [Installation de bibliothèques Python supplémentaires dans AWS Glue 5.0 à l'aide de requirements.txt](#).
- AWS Glue La version 5.0 prend en charge le lignage des données sur Amazon DataZone. Vous pouvez configurer AWS Glue pour collecter automatiquement des informations de lignage lors de l'exécution des tâches Spark et envoyer les événements de lignage à visualiser sur Amazon DataZone. Pour plus d'informations, consultez la section [Lignage des données sur Amazon DataZone](#).

Pour le configurer sur la AWS Glue console, activez `Generate lineage events` et saisissez votre identifiant de DataZone domaine Amazon dans l'onglet `Job details`.

Visual	Script	Job details	Runs	Data quality	Schedules	Version Control	Upgrades
Generate lineage events ☒ AWS Glue will capture Spark lineage events from your job runs and send them to Amazon DataZone or next generation of Amazon Sagemaker to visualize the table and column lineage. Domain ID The identifier of the specified domain. dzd_test_domain							

Vous pouvez également fournir le paramètre de tâche suivant (indiquez votre ID de DataZone domaine) :

- Clé : `--conf`
- Valeur :

```
extraListeners=io.openlineage.spark.agent.OpenLineageSparkListener
--conf spark.openlineage.transport.type=amazon_datazone_api
--conf spark.openlineage.transport.domainId=<your-domain-ID>
```

- Mises à jour du connecteur et du pilote JDBC. Pour plus d'informations, consultez [Annexe B : Mises à niveau du pilote JDBC](#) et [Annexe C : Mises à niveau des connecteurs](#).
- Mise à jour de Java de 8 à 17.
- Stockage accru pour les G.2X employés AWS Glue G.1X et les employés, l'espace disque passant respectivement à 94 Go et 138 Go. Pour de plus amples informations, consultez [Tâches](#).
- Support pour les tâches AWS SDK for Java, versions 2 AWS Glue à 5.0, peuvent utiliser les [versions](#) 1.12.569 [ou](#) 2.28.8 pour Java si la tâche prend en charge la version v2. Le AWS SDK pour Java 2.x est une réécriture majeure de la base de code de la version 1.x. Il repose sur Java 8+ et ajoute plusieurs fonctionnalités fréquemment demandées. Cela inclut la prise en charge d'E/S non bloquantes et la possibilité de brancher une implémentation HTTP différente au moment de l'exécution. Pour plus d'informations, y compris un guide de migration du SDK pour Java v1 vers la v2, consultez [AWS le guide du SDK pour Java](#), version 2.

-

Évolutions

Notez les modifications majeures suivantes :

- Dans la AWS Glue version 5.0, lorsque vous utilisez le système de fichiers S3A et si ``fs.s3a.endpoint`` et ``fs.s3a.endpoint.region`` ne sont pas définis, la région par défaut utilisée par S3A est ``us-east-2``. Cela peut entraîner des problèmes, tels que des erreurs de délai de chargement dans S3, en particulier pour les tâches VPC. Pour atténuer les problèmes causés par cette modification, définissez la configuration Spark ``fs.s3a.endpoint.region`` lorsque vous utilisez le système de fichiers S3A dans la version 5.0. AWS Glue
- Contrôle d'accès à grain fin (FGAC) en formation lacustre
 - AWS Glue La version 5.0 prend uniquement en charge le nouveau FGAC natif de Spark utilisant Spark. DataFrames Il ne prend pas en charge l'utilisation AWS Glue DynamicFrames du FGAC.
 - L'utilisation de FGAC dans la version 5.0 nécessite une migration depuis Spark AWS Glue DynamicFrames DataFrames
 - Si vous n'avez pas besoin du FGAC, il n'est pas nécessaire de migrer vers Spark DataFrame et les GlueContext fonctionnalités, telles que les signets de tâches et les prédicats push down, continueront de fonctionner.
 - Les tâches avec le FGAC natif de Spark nécessitent un minimum de 4 travailleurs : un pilote utilisateur, un pilote système, un exécutateur système et un exécutateur utilisateur de secours.
 - Pour plus d'informations, consultez la section [Utilisation AWS Glue avec AWS Lake Formation pour un contrôle d'accès précis](#).
- Accès complet à la table Lake Formation (FTA)
 - AWS Glue 5.0 prend en charge le FTA avec Spark native DataFrames (nouveau) et GlueContext DynamicFrames (ancien, avec des limitations)
 - Accord de libre-échange natif de Spark
 - Si le script 4.0 l'utilise GlueContext, migrez vers Native Spark.
 - Cette fonctionnalité est limitée aux tables Hive et Iceberg
 - Pour plus d'informations sur la configuration d'une tâche 5.0 pour utiliser le FTA natif de Spark, voir
 - GlueContext DynamicFrame ALE
 - Aucune modification de code n'est nécessaire
 - Cette fonctionnalité est limitée aux tables non OTF. Elle ne fonctionnera pas avec Iceberg, Delta Lake et Hudi.
- Le [lecteur CSV SIMD vectorisé](#) n'est pas pris en charge.
- [La journalisation continue](#) dans le groupe de journaux de sortie n'est pas prise en charge. Utilisez plutôt un groupe de ~~error~~ journaux.

- Le AWS Glue Job Run Insights `job-insights-rule-driver` est devenu obsolète. Le flux du `job-insights-rca-driver` journal se trouve désormais dans le groupe des journaux d'erreurs.
- Les custom/marketplace connecteurs basés sur Athena ne sont pas pris en charge.
- Les connecteurs Adobe Marketo Engage, Facebook Ads, Google Ads, Google Analytics 4, Google Sheets, Hubspot, Instagram Ads, Intercom, Jira Cloud, Oracle, Salesforce, Salesforce Marketing Cloud NetSuite, Salesforce Marketing Cloud Account Engagement, SAP, Slack, Snapchat Ads OData ServiceNow, Stripe, Zendesk et Zoho CRM ne sont pas pris en charge.
- Les propriétés log4j personnalisées ne sont pas prises en charge dans AWS Glue la version 5.0.

Améliorations majeures de Spark 3.3.0 à Spark 3.5.4

Notez les améliorations suivantes :

- Client Python pour Spark Connect ([SPARK-39375](#)).
- Implémenter le support des valeurs DEFAULT pour les colonnes des tables ([SPARK-38334](#)).
- Support « Références d'alias de colonne latérale » ([SPARK-27561](#)).
- [Renforcez l'utilisation de SQLSTATE pour les classes d'erreur \(SPARK-41994\)](#).
- Activez les jointures du filtre Bloom par défaut ([SPARK-38841](#)).
- Amélioration de l'évolutivité de l'interface utilisateur Spark et de la stabilité des pilotes pour les applications de grande envergure ([SPARK-41053](#)).
- Suivi de la progression asynchrone dans le streaming structuré ([SPARK-39591](#)).
- Traitement dynamique arbitraire en Python dans le streaming structuré ([SPARK-40434](#)).
- [Améliorations de la couverture de l'API Pandas \(SPARK-42882\) et de la prise en charge des NumPy entrées dans \(SPARK-39405\). PySpark](#)
- Fournissez un profileur de mémoire pour les fonctions PySpark définies par l'utilisateur ([SPARK-40281](#)).
- PyTorch Distributeur d'outils ([SPARK-41589](#)).
- Publiez des artefacts SBOM ([SPARK-41893](#)).
- Support IPv6 uniquement pour l'environnement ([SPARK-39457](#)).
- [Planificateur K8s personnalisé \(Apache YuniKorn et Volcano\) GA \(SPARK-42802\)](#).
- [Support client Scala et Go dans Spark Connect \(SPARK-42554\) et \(SPARK-43351\)](#).
- PyTorchSupport ML distribué basé sur Spark Connect ([SPARK-42471](#)).

- Support de streaming structuré pour Spark Connect en Python et Scala ([SPARK-42938](#)).
- Support de l'API Pandas pour le client Python Spark Connect ([SPARK-42497](#)).
- Présentez Arrow Python UDFs ([SPARK-40307](#)).
- Support des fonctions de table définies par l'utilisateur en Python ([SPARK-43798](#)).
- Migrez PySpark les erreurs vers les classes d'erreurs ([SPARK-42986](#)).
- PySpark cadre de test ([SPARK-44042](#)).
- Ajout du support pour Datasketches HllSketch ([SPARK-16484](#)).
- Amélioration de la fonction SQL intégrée ([SPARK-41231](#)).
- Clause IDENTIFIER ([SPARK-43205](#)).
- Ajoutez des fonctions SQL dans Scala, Python et R API ([SPARK-43907](#)).
- Ajout de la prise en charge des arguments nommés pour les fonctions SQL ([SPARK-43922](#)).
- [Évitez de réexécuter une tâche inutile en cas de perte d'un exécuteur hors service en cas de migration des données shuffle](#) ([SPARK-41469](#)).
- ML distribué <> Spark Connect ([SPARK-42471](#)).
- DeepSpeed distributeur ([SPARK-44264](#)).
- [Implémentez le point de contrôle du journal des modifications pour le magasin d'état RockSDB](#) ([SPARK-43421](#)).
- Introduisez la propagation des filigranes parmi les opérateurs ([SPARK-42376](#)).
- Présentez dropDuplicatesWithin Watermark ([SPARK-42931](#)).
- Améliorations apportées à la gestion de la mémoire du fournisseur RockSDB State Store ([SPARK-43311](#)).

Actions pour migrer vers la AWS Glue version 5.0

Pour les tâches existantes, modifiez la Glue version depuis la version précédente vers Glue 5.0 dans la configuration de la tâche.

- Dans AWS Glue Studio, choisissez « Glue 5.0 - Supports Spark 3.5.4, Scala 2, Python 3 in Glue version ».
- Dans l'API, choisissez 5.0 dans le paramètre GlueVersion de l'opération d'API [UpdateJob](#).

Pour les nouvelles tâches, choisissez Glue 5.0 lorsque vous créez une tâche.

- Dans la console, choisissez Spark 3.5.4, Python 3 (Glue Version 5.0) or Spark 3.5.4, Scala 2 (Glue Version 5.0) dans Glue version.
- Dans AWS Glue Studio, choisissez « Glue 5.0 - Supports Spark 3.5.4, Scala 2, Python 3 in Glue version ».
- Dans l'API, choisissez 5.0 dans le paramètre GlueVersion de l'opération d'API [CreateJob](#).

Pour consulter les journaux d'événements Spark de la AWS Glue version 5.0 à partir de la version AWS Glue 2.0 ou d'une version antérieure, [lancez un serveur d'historique Spark mis à niveau pour la AWS Glue version 5.0 à l'aide AWS CloudFormation de Docker](#).

Liste de contrôle de migration

Consultez cette liste de contrôle pour la migration :

- Mises à jour de Java 17
- [Scala] Mettre à niveau les appels du AWS SDK de la v1 à la v2
- Migration de Python 3.10 vers 3.11
- [Python] Mettre à jour les références de démarrage de la version 1.26 à la version 1.34

AWS Glue Caractéristiques de la version 5.0

Cette section décrit les AWS Glue fonctionnalités de manière plus détaillée.

Interrogation de catalogues de données de métastore à partir de l'ETL AWS Glue

Vous pouvez enregistrer votre AWS Glue travail pour accéder au AWS Glue Data Catalog, qui met les tables et autres ressources de métastore à la disposition de clients disparates. Le catalogue de données prend en charge une hiérarchie de catalogues multiples, qui unifie toutes vos données dans les lacs de données Amazon S3. Il fournit également une API de métastore Hive et une API Apache Iceberg open source pour accéder aux données. Ces fonctionnalités sont disponibles pour AWS Glue d'autres services axés sur les données tels qu'Amazon EMR, Amazon Athena et Amazon Redshift.

Lorsque vous créez des ressources dans le catalogue de données, vous pouvez y accéder à partir de n'importe quel moteur SQL prenant en charge l'API REST Apache Iceberg. AWS Lake Formation gère les autorisations. Après la configuration, vous pouvez tirer parti des capacités AWS Glue de l'application pour interroger des données disparates en interrogeant ces ressources de métastore avec des applications familières. Il s'agit notamment d'Apache Spark et de Trino.

Comment les ressources de métadonnées sont organisées

Les données sont organisées selon une hiérarchie logique de catalogues, de bases de données et de tables, à l' AWS Glue Data Catalog aide des éléments suivants :

- Catalogue : conteneur logique qui contient des objets provenant d'un magasin de données, tels que des schémas ou des tables.
- Base de données : organise les objets de données tels que les tables et les vues dans un catalogue.
- Tables et vues : objets de données d'une base de données qui fournissent une couche d'abstraction avec un schéma compréhensible. Ils facilitent l'accès aux données sous-jacentes, qui peuvent être dans différents formats et à différents endroits.

Migration de la AWS Glue version 4.0 vers AWS Glue la version 5.0

Tous les paramètres de travail existants et les principales fonctionnalités qui existent dans la AWS Glue version 4.0 existeront dans la AWS Glue version 5.0, à l'exception des transformations liées à l'apprentissage automatique.

Les nouveaux paramètres suivants ont été ajoutés :

- `--enable-lakeformation-fine-grained-access`: Active la fonctionnalité de contrôle d'accès détaillé (FGAC) dans les tables de AWS Lake Formation.

Reportez-vous à la documentation sur la migration de Spark :

- [Guide de migration : Spark Core](#)
- [Guide de migration : SQL, ensembles de données et DataFrame](#)
- [Guide de migration : Streaming structuré](#)
- [Upgrading PySpark](#)

Migration de la AWS Glue version 3.0 à AWS Glue la version 5.0

Note

Pour les étapes de migration liées à la AWS Glue version 4.0, voir [Migration de la AWS Glue version 3.0 à AWS Glue la version 4.0](#).

Tous les paramètres de travail existants et les fonctionnalités principales qui existent dans la AWS Glue version 3.0 existeront dans la AWS Glue version 5.0, à l'exception des transformations de machine learning.

Migration de la AWS Glue version 2.0 vers AWS Glue la version 5.0

Note

Pour les étapes de migration liées à la version AWS Glue 4.0 et la liste des différences de migration entre les AWS Glue versions 3.0 et 4.0, voir [Migration de la AWS Glue version 3.0 à AWS Glue la version 4.0](#).

Notez également les différences de migration suivantes entre AWS Glue les versions 3.0 et 2.0 :

- Tous les paramètres de travail existants et les fonctionnalités principales qui existent dans la AWS Glue version 2.0 existeront dans la AWS Glue version 5.0, à l'exception des transformations de machine learning.
- Plusieurs modifications Spark peuvent à elles seules nécessiter une révision de vos scripts pour s'assurer que les fonctions supprimées ne sont pas référencées. Par exemple, Spark 3.1.1 et versions ultérieures n'activent pas Scala-Untyped, UDFs mais Spark 2.4 le permet.
- Python 2.7 n'est pas pris en charge.
- Tout fichier jar supplémentaire fourni dans les tâches AWS Glue 2.0 existantes peut entraîner des dépendances conflictuelles, car plusieurs dépendances ont été mises à niveau. Vous pouvez éviter les conflits de chemin de classe avec le paramètre de `--user-jars-first` tâche.
- Modifications du comportement des fichiers loading/saving de from/to parquet horodatés. Pour plus de détails, veuillez consulter Mise à niveau de Spark SQL 3.0 vers 3.1.
- Parallélisme différent des tâches Spark pour driver/executor la configuration. Vous pouvez ajuster le parallélisme des tâches en transmettant l'argument `--executor-cores` job.

Changements de comportement de journalisation dans la AWS Glue version 5.0

Les modifications apportées au comportement de journalisation dans la AWS Glue version 5.0 sont les suivantes. Pour plus d'informations, consultez la section [Journalisation des AWS Glue tâches](#).

- Tous les journaux (journaux du système, journaux du démon Spark, journaux des utilisateurs et journaux Glue Logger) sont désormais écrits dans le `/aws-glue/jobs/error` groupe de journaux par défaut.
- Le groupe de `/aws-glue/jobs/logs-v2` journaux utilisé pour la journalisation continue dans les versions précédentes n'est plus utilisé.
- Vous ne pouvez plus renommer ou personnaliser les noms des groupes de journaux ou des flux de journaux à l'aide des arguments de journalisation continue supprimés. Consultez plutôt les nouveaux arguments de tâche dans la AWS Glue version 5.0.

Deux nouveaux arguments de travail sont introduits dans la AWS Glue version 5.0

- `--custom-logGroup-prefix`: vous permet de spécifier un préfixe personnalisé pour les groupes de `/aws-glue/jobs/output` journaux `/aws-glue/jobs/error` et.
- `--custom-logStream-prefix`: vous permet de spécifier un préfixe personnalisé pour les noms des flux de journaux au sein des groupes de journaux.

Les règles de validation et les limitations relatives aux préfixes personnalisés incluent :

- Le nom complet du flux de log doit comporter entre 1 et 512 caractères.
- Le préfixe personnalisé pour les noms des flux de journaux est limité à 400 caractères.
- Les caractères autorisés dans les préfixes incluent les caractères alphanumériques, les traits de soulignement (`_`), les traits d'union (`-`) et les barres obliques (`/`).

Arguments de journalisation continue obsolètes dans la version 5.0 AWS Glue

Les arguments de tâche suivants pour la journalisation continue ont été déconseillés dans la version 5.0 AWS Glue

- `--enable-continuous-cloudwatch-log`
- `--continuous-log-logGroup`
- `--continuous-log-logStreamPrefix`
- `--continuous-log-conversionPattern`

- `--enable-continuous-log-filter`

Migration du connecteur et du pilote JDBC pour la version 5.0 AWS Glue

Pour en savoir plus sur les versions des connecteurs JDBC et de lac de données qui ont été mises à niveau, consultez :

- [Annexe B : Mises à niveau du pilote JDBC](#)
- [Annexe C : Mises à niveau des connecteurs](#)
- [Annexe D : Mises à niveau du format de tableau ouvert](#)

Les modifications suivantes s'appliquent aux versions du connecteur ou du pilote identifiées dans les annexes de Glue 5.0.

Amazon Redshift

Notez les modifications suivantes :

- Ajoute la prise en charge des noms de table en trois parties pour permettre au connecteur d'interroger les tables de partage de données Redshift.
- Corrige le mappage de Spark `ShortType` pour utiliser Redshift `SMALLINT` plutôt que `INTEGER` pour mieux correspondre à la taille de données attendue.
- Ajout de la prise en charge des noms de cluster personnalisés (CNAME) pour Amazon Redshift Serverless.

Apache Hudi

Notez les modifications suivantes :

- Support : indice de niveau record.
- Support de génération auto de clés d'enregistrement. Désormais, il n'est plus nécessaire de spécifier le champ clé d'enregistrement.

Apache Iceberg

Notez les modifications suivantes :

- Support d'un contrôle d'accès précis avec. AWS Lake Formation
- Support du branchement et du balisage, qui sont des références nommées à des instantanés dotés de leur propre cycle de vie indépendant.
- Ajout d'une procédure d'affichage du journal des modifications qui génère une vue contenant les modifications apportées à une table au cours d'une période spécifiée ou entre des instantanés spécifiques.

Delta Lake

Notez les modifications suivantes :

- Support du format Delta Universal (UniForm) qui permet un accès fluide via Apache Iceberg et Apache Hudi.
- Support des vecteurs de suppression qui implémentent un Merge-on-Read paradigme.

AzureCosmos

Notez les modifications suivantes :

- Ajout du support des clés de partition hiérarchiques.
- Ajout d'une option permettant d'utiliser un schéma personnalisé avec StringType (json brut) pour une propriété imbriquée.
- Ajout d'une option `spark.cosmos.auth.aad.clientCertPemBase64` de configuration pour permettre d'utiliser l'authentification SPN (ServicePrincipal nom) avec un certificat au lieu du secret client.

Pour plus d'informations, consultez le [journal des modifications du connecteur Azure Cosmos DB Spark](#).

Microsoft SQL Server

Notez les modifications suivantes :

- Le chiffrement TLS est activé par défaut.
- Lorsque `encrypt = false` mais que le serveur exige le chiffrement, le certificat est validé en fonction du paramètre de `trustServerCertificate` connexion.
- `aadSecurePrincipalId` et `aadSecurePrincipalSecret` obsolète.

- `getAADSecretPrincipalIdAPI` supprimée.
- Résolution CNAME ajoutée lorsque le domaine est spécifié.

MongoDB

Notez les modifications suivantes :

- Support du mode micro-batch avec Spark Structured Streaming.
- Support pour les types de données BSON.
- Ajout de la prise en charge de la lecture de plusieurs collections lors de l'utilisation des modes microbatch ou de diffusion continue.
 - Si le nom d'une collection utilisée dans votre option de `collection` configuration contient une virgule, le connecteur Spark la traite comme deux collections différentes. Pour éviter cela, vous devez éviter la virgule en la faisant précéder d'une barre oblique inverse (`\`).
 - Si le nom d'une collection utilisée dans votre option de `collection` configuration est « `*` », le connecteur Spark l'interprète comme une spécification pour scanner toutes les collections. Pour éviter cela, vous devez éviter l'astérisque en le faisant précéder d'une barre oblique inverse (`\`).
 - Si le nom d'une collection utilisée dans votre option de `collection` configuration contient une barre oblique inverse (`\`), le connecteur Spark traite la barre oblique inverse comme un caractère d'échappement, ce qui peut modifier la façon dont il interprète la valeur. Pour éviter cela, vous devez éviter la barre oblique inverse en la faisant précéder d'une autre barre oblique inverse.

Pour plus d'informations, consultez les notes de [version du connecteur MongoDB pour Spark](#).

Snowflake

Notez les modifications suivantes :

- Ajout d'un nouveau `trim_space` paramètre que vous pouvez utiliser pour réduire automatiquement les valeurs des `StringType` colonnes lors de l'enregistrement dans une table Snowflake. Par défaut: `false`.
- Le `abort_detached_query` paramètre a été désactivé par défaut au niveau de la session.
- Suppression de l'exigence du `SFUSER` paramètre lors de l'utilisation d'OAUTH.
- Suppression de la fonctionnalité Advanced Query Pushdown. Des alternatives à cette fonctionnalité sont disponibles. Par exemple, au lieu de charger des données à partir de tables Snowflake, les utilisateurs peuvent charger directement des données à partir de requêtes SQL Snowflake.

Pour plus d'informations, consultez les notes de [mise à jour du connecteur Snowflake pour Spark](#).

Annexe A : Mises à niveau notables des dépendances

Voici les mises à niveau des dépendances :

Dépendance	Version en AWS Glue 5.0	Version en AWS Glue 4.0	Version en AWS Glue 3.0	Version en AWS Glue 2.0	Version en AWS Glue 1.0
Java	17	8	8	8	8
Spark	3.5.4	3.3.0-amzn-1	3.1.1-amzn-0	2.4.3	2.4.3
Hadoop	3.4.1	3.3.3-amzn-0	3.2.1-amzn-3	2.8.5-amzn-5	2.8.5-amzn-1
Scala	2,1,18	2,12	2,12	2.11	2.11
Jackson	2.15.2	2,12	2,12	2.11	2.11
Hive	2.3.9-amzn-4	2.3.9-amzn-2	2.3.7-amzn-4	1.2	1.2
EMRFS	2,69,0	2,54,0	2,46,0	2.38.0	2.30.0
Json4s	3.7.0-M11	3.7.0-M11	3.6.6	3.5.x	3.5.x
Flèche	12,0.1	7.0.0	2.0.0	0.10.0	0.10.0
AWS Glue Client de catalogue de données	4.5.0	3.7.0	3.0.0	1.10.0	N/A
AWS SDK pour Java	2,29,52	1.12	1.12		
Python	3,11	3,10	3.7	2.7 et 3.6	2.7 et 3.6
Boto	1,34,131	1,26	1,18	1.12	N/A

Dépendance	Version en AWS Glue 5.0	Version en AWS Glue 4.0	Version en AWS Glue 3.0	Version en AWS Glue 2.0	Version en AWS Glue 1.0
Connecteur EMR DynamoDB	5.6.0	4,16,0			

Annexe B : Mises à niveau du pilote JDBC

Voici les mises à niveau du pilote JDBC :

Pilote	Version du pilote JDBC en 5.0 AWS Glue	Version du pilote JDBC en 4.0 AWS Glue	Version du pilote JDBC en 3.0 AWS Glue	Version du pilote JDBC dans les versions précédentes AWS Glue
MySQL	8,0,33	8.0.23	8.0.23	5.1
Microsoft SQL Server	10.2.0	9.4.0	7.0.0	6.1.0
Oracle Databases	23,3.0,23,09	21,7	21,1	11.2
PostgreSQL	42.7.3	42,3.6	42,2,18	42,10
Amazon Redshift	redshift-jdbc42-2.1.0.29	redshift-jdbc42-2.1.0.16	redshift-jdbc41-1.2.12.1017	redshift-jdbc41-1.2.12.1017
SAP Hana	2,20,17	2,17,12		
Teradata	20,00.00.33	20,00.00.06		

Annexe C : Mises à niveau des connecteurs

Les mises à niveau des connecteurs sont les suivantes :

Pilote	Version du connecteur en AWS Glue 5.0	Version du connecteur en AWS Glue 4.0	Version du connecteur en AWS Glue 3.0
Connecteur EMR DynamoDB	5.6.0	4,16,0	
Amazon Redshift	6.4.0	6.1.3	
OpenSearch	1.2.0	1.0.1	
MongoDB	10.4.0	10,0.4	3.0.0
Snowflake	3.0.0	2.12.0	
Google BigQuery	0,32,2	0,32,2	
AzureCosmos	4,33,0	4,22,0	
AzureSQL	1.3.0	1.3.0	
Vertica	3.3.5	3.3.5	

Annexe D : Mises à niveau du format de tableau ouvert

Les mises à niveau du format de table ouverte sont les suivantes :

OTF	Version du connecteur en AWS Glue 5.0	Version du connecteur en AWS Glue 4.0	Version du connecteur en AWS Glue 3.0
Hudi	0,15,0	0.12.1	0,1,1
Delta Lake	3.3.0	2.1.0	1.0.0
Iceberg	1.7.1	1.0.0	0.13.1

Migration AWS Glue des tâches Spark vers la AWS Glue version 4.0

Cette rubrique décrit les modifications apportées entre AWS Glue les versions 0.9, 1.0, 2.0 et 3.0 pour vous permettre de migrer vos applications Spark et vos tâches ETL vers la AWS Glue version 4.0. Il décrit également les fonctionnalités de la AWS Glue version 4.0 et les avantages de son utilisation.

Pour utiliser cette fonctionnalité avec vos tâches AWS Glue ETL, **4.0** choisissez-la Glue version lors de la création de vos tâches.

Rubriques

- [Nouvelles fonctionnalités prises en charge](#)
- [Actions relatives à la migration vers AWS Glue 4.0](#)
- [Liste de contrôle de migration](#)
- [Migration de la AWS Glue version 3.0 à AWS Glue la version 4.0](#)
- [Migration de la AWS Glue version 2.0 vers AWS Glue la version 4.0](#)
- [Migration de la AWS Glue version 1.0 à AWS Glue la version 4.0](#)
- [Migration de la version AWS Glue 0.9 à AWS Glue la version 4.0](#)
- [Migration du connecteur et du pilote JDBC pour la version 4.0 AWS Glue](#)
- [Annexe A : Mises à niveau notables des dépendances](#)
- [Annexe B : Mises à niveau du pilote JDBC](#)
- [Annexe C : Mises à niveau des connecteurs](#)

Nouvelles fonctionnalités prises en charge

Cette section décrit les nouvelles fonctionnalités et les avantages de la AWS Glue version 4.0.

- Elle est basée sur Apache Spark 3.3.0, mais propose des optimisations dans AWS Glue et Amazon EMR, telles que les exécutions adaptatives de requêtes, les lecteurs vectorisés, les remaniements optimisés et la fusion de partitions.
- Pilotes JDBC mis à niveau pour toutes les sources AWS Glue natives, notamment MySQL, Microsoft SQL Server, Oracle, PostgreSQL, MongoDB, ainsi que les bibliothèques et dépendances Spark mises à niveau introduites par Spark 3.3.0.
- Utilisation d'un nouveau connecteur Amazon Redshift et d'un nouveau pilote JDBC.

- Accès optimisé à Amazon S3 avec EMRFS (système de fichiers EMR) mis à niveau et validateurs de sortie optimisés Amazon S3 activés par défaut.
- Accès optimisé au catalogue de données avec des index de partition, le déploiement des prédicats, une liste de partitions et un client de métastore Hive mis à niveau.
- Intégration à Lake Formation pour les tables de catalogue régies avec filtrage au niveau des cellules et transactions de lac de données.
- Réduction de la latence au démarrage afin d'améliorer les temps globaux de réalisation de tâche et l'interactivité.
- Les tâches Spark sont facturées par incréments d'une seconde avec une durée de facturation minimale 10 fois inférieure, allant d'un minimum de 10 minutes à un minimum de 1 minute.
- Prise en charge native des infrastructures de lacs de données ouverts avec Apache Hudi, Delta Lake et Apache Iceberg.
- Prise en charge native du plug-in Cloud Shuffle Storage basé sur Amazon S3 (un plug-in Apache Spark) permettant d'utiliser Amazon S3 pour la réorganisation et la capacité de stockage élastique.

Améliorations majeures de Spark 3.1.1 à Spark 3.3.0

Notez les améliorations suivantes :

- Filtrage d'exécution au niveau des lignes ([SPARK-32268](#)).
- Améliorations ANSI ([SPARK-38860](#)).
- Améliorations des messages d'erreur ([SPARK-38781](#)).
- Prise en charge des types complexes pour le lecteur vectorisé Parquet ([SPARK-34863](#)).
- Prise en charge des métadonnées de fichiers masqués pour Spark SQL ([SPARK-37273](#)).
- [Fournissez un profileur pour Python/Pandas UDFs \(SPARK-37443\)](#).
- Présentez Trigger. AvailableNow [pour exécuter des requêtes de streaming telles que Trigger.Once en plusieurs lots \(SPARK-36533\)](#).
- Fonctionnalités pushdown de Datasource V2 plus complètes ([SPARK-38788](#)).
- Migration de log4j 1 vers log4j 2 ([SPARK-37814](#)).

Autres changements notables

Notez les modifications suivantes :

- Évolutions

- Abandon des références à la prise en charge de Python 3.6 dans les documentations et Python/docs ([SPARK-36977](#)).
- Suppression du tuple hack nommé en remplaçant le pickle intégré par cloudpickle ([SPARK-32079](#)).
- Passage de la version minimale de Pandas à 1.0.5 ([SPARK-37465](#)).

Actions relatives à la migration vers AWS Glue 4.0

Pour les tâches existantes, modifiez la Glue version depuis la version précédente vers Glue 4.0 dans la configuration de la tâche.

- Dans AWS Glue Studio, choisissez « Glue 4.0 - Supports Spark 3.3, Scala 2, Python 3 in Glue version ».
- Dans l'API, choisissez **4.0** dans le paramètre GlueVersion de l'opération d'API [UpdateJob](#).

Pour les nouvelles tâches, choisissez Glue 4.0 lorsque vous créez une tâche.

- Dans la console, choisissez Spark 3.3, Python 3 (Glue Version 4.0) or Spark 3.3, Scala 2 (Glue Version 3.0) dans Glue version.
- Dans AWS Glue Studio, choisissez « Glue 4.0 - Supports Spark 3.3, Scala 2, Python 3 in Glue version ».
- Dans l'API, choisissez **4.0** dans le paramètre GlueVersion de l'opération d'API [CreateJob](#).

Pour consulter les journaux d'événements Spark AWS Glue 4.0 issus de la version AWS Glue 2.0 ou d'une version antérieure, [lancez un serveur d'historique Spark mis à niveau pour AWS Glue 4.0 à l'aide AWS CloudFormation de Docker](#).

Liste de contrôle de migration

- Les bibliothèques Python externes de votre tâche dépendent-elles de Python 2.7/3.6 ?
 - Mettez à jour les bibliothèques dépendantes de Python 2.7/3.6 vers Python 3.10, car Spark 3.3.0 a supprimé la prise en charge de Python 2.7 et 3.6.

Migration de la AWS Glue version 3.0 à AWS Glue la version 4.0

Notez les modifications suivantes lors de la migration :

- Tous les paramètres de travail existants et les fonctionnalités principales qui existent dans la AWS Glue version 3.0 existeront dans la AWS Glue version 4.0.
- AWS Glue La version 3.0 utilise Spark 3.1.1 optimisé pour Amazon EMR, et la version 4.0 AWS Glue utilise Spark 3.3.0 optimisé pour Amazon EMR.

Plusieurs modifications Spark pourraient à elles seules nécessiter une révision de vos scripts pour s'assurer que les fonctions supprimées ne sont pas référencées.

- AWS Glue La version 4.0 inclut également une mise à jour d'EMRFS et de Hadoop. Pour en savoir plus sur cette version spécifique, consultez [Annexe A : Mises à niveau notables des dépendances](#).
- Le AWS SDK fourni dans les tâches ETL est désormais mis à niveau de la version 1.11 à la version 1.12.
- Toutes les tâches Python utiliseront la version 3.10 de Python. Auparavant, Python 3.7 était utilisé dans la AWS Glue version 3.0.

Par conséquent, certains pymodules proposés AWS Glue sont mis out-of-the-box à niveau.

- Log4j a été mis à niveau vers Log4j2.
 - Pour plus d'informations sur le chemin de migration Log4j2, consultez la [documentation de Log4j](#).
 - Vous devez plutôt renommer tout fichier log4j.properties personnalisé comme fichier log4j2.properties, avec les propriétés log4j2 appropriées.
- Pour la migration de certains connecteurs, consultez [Migration du connecteur et du pilote JDBC pour la version 4.0 AWS Glue](#).
- Le SDK de AWS chiffrement est mis à niveau de la version 1.x à la version 2.x. AWS Glue les tâches utilisant des configurations AWS Glue de sécurité et les tâches dépendantes de la dépendance du SDK de AWS chiffrement fournie lors de l'exécution sont affectées. Consultez les instructions relatives à la migration des AWS Glue tâches.

Vous pouvez mettre à niveau en toute sécurité une tâche AWS Glue 2.0/3.0 vers une tâche AWS Glue 4.0, car la version AWS Glue 2.0/3.0 contient déjà la version pont du SDK de AWS chiffrement.

Reportez-vous à la documentation sur la migration de Spark :

- [Upgrading from Spark SQL 3.1 to 3.2](#)
- [Upgrading from Spark SQL 3.2 to 3.3](#)

Migration de la AWS Glue version 2.0 vers AWS Glue la version 4.0

Notez les modifications suivantes lors de la migration :

Note

Pour les étapes de migration liées à la AWS Glue version 3.0, voir [Migration de la AWS Glue version 3.0 à AWS Glue la version 4.0](#).

- Tous les paramètres de travail existants et les principales fonctionnalités qui existent dans la AWS Glue version 2.0 existeront dans la AWS Glue version 4.0.
- Le validateur EMRFS S3 optimisé pour écrire des données Parquet dans Amazon S3 est activé par défaut depuis la version 3.0. AWS Glue Cependant, vous pouvez toujours le désactiver en définissant `--enable-s3-parquet-optimized-committer` sur `false`.
- AWS Glue La version 2.0 utilise le logiciel libre Spark 2.4 et la AWS Glue version 4.0 utilise Spark 3.3.0 optimisé pour Amazon EMR.
 - Plusieurs modifications Spark peuvent à elles seules nécessiter une révision de vos scripts pour s'assurer que les fonctions supprimées ne sont pas référencées.
 - Par exemple, Spark 3.3.0 n'active pas Scala-Untyped UDFs, mais Spark 2.4 le permet.
- Le AWS SDK fourni dans les tâches ETL est désormais mis à niveau de la version 1.11 à la version 1.12.
- AWS Glue La version 4.0 inclut également une mise à jour d'EMRFS, des pilotes JDBC mis à jour et l'inclusion d'optimisations supplémentaires sur Spark lui-même fournies par. AWS Glue
- Scala est mis à jour depuis la version 2.11 vers la version 2.12, et Scala 2.12 n'est pas rétrocompatible avec Scala 2.11.
- Python 3.10 est la version utilisée par défaut pour les scripts Python, comme AWS Glue 2.0 utilisait uniquement Python 3.7 et 2.7.
 - Python 2.7 n'est pas pris en charge avec Spark 3.3.0. Toute tâche demandant Python 2 dans la configuration de la tâche échouera avec un `IllegalArgumentException`.
 - Un nouveau mécanisme d'installation de modules Python supplémentaires est disponible depuis la AWS Glue version 2.0.
- Plusieurs mises à jour de dépendance, mises en évidence dans [Annexe A : Mises à niveau notables des dépendances](#).

- Tout fichier JAR supplémentaire fourni dans les tâches AWS Glue 2.0 existantes peut entraîner des dépendances conflictuelles car plusieurs dépendances ont été mises à niveau dans la version 4.0 par rapport à la version 2.0. Vous pouvez éviter les conflits de chemin de classe dans la AWS Glue version 4.0 avec le paramètre `--user-jars-first` AWS Glue job.
- AWS Glue La version 4.0 utilise Spark 3.3. À partir de Spark 3.1, le comportement des fichiers de loading/saving of timestamps from/to parquet a changé. Pour plus de détails, veuillez consulter [Mise à niveau de Spark SQL 3.0 vers 3.1](#).

Nous vous recommandons de définir les paramètres suivants lors de la lecture/écriture de données Parquet contenant des colonnes d'horodatage. La définition de ces paramètres peut résoudre le problème d'incompatibilité du calendrier qui se produit lors de la mise à niveau de Spark 2 vers Spark 3, tant pour le AWS Glue Dynamic Frame que pour le Spark Data Frame. Utilisez l'option `CORRECTED` pour lire la valeur datetime telle quelle, et l'option `LEGACY` pour rebaser les valeurs datetime par rapport à la différence de calendrier pendant la lecture.

```
- Key: --conf
- Value: spark.sql.legacy.parquet.int96RebaseModeInRead=[CORRECTED|LEGACY] --
conf spark.sql.legacy.parquet.int96RebaseModeInWrite=[CORRECTED|LEGACY] --conf
spark.sql.legacy.parquet.datetimeRebaseModeInRead=[CORRECTED|LEGACY]
```

- Pour la migration de certains connecteurs, consultez [Migration du connecteur et du pilote JDBC pour la version 4.0 AWS Glue](#).
- Le SDK de AWS chiffrement est mis à niveau de la version 1.x à la version 2.x. AWS Glue les tâches utilisant des configurations AWS Glue de sécurité et les tâches dépendantes de la dépendance du SDK de AWS chiffrement fournie lors de l'exécution sont affectées. Consultez ces instructions pour la migration des AWS Glue tâches :
 - Vous pouvez mettre à niveau une tâche AWS Glue 2.0 vers une tâche AWS Glue 4.0 en toute sécurité, car la version AWS Glue 2.0 contient déjà la version pont du SDK de AWS chiffrement.

Reportez-vous à la documentation sur la migration de Spark :

- [Upgrading from Spark SQL 2.4 to 3.0](#)
- [Upgrading from Spark SQL 3.1 to 3.2](#)
- [Upgrading from Spark SQL 3.2 to 3.3](#)
- [Changes in Datetime behavior to be expected since Spark 3.0.](#)

Migration de la AWS Glue version 1.0 à AWS Glue la version 4.0

Notez les modifications suivantes lors de la migration :

- AWS Glue La version 1.0 utilise le logiciel libre Spark 2.4 et la AWS Glue version 4.0 utilise Spark 3.3.0 optimisé pour Amazon EMR.
- Plusieurs modifications Spark peuvent à elles seules nécessiter une révision de vos scripts pour s'assurer que les fonctions supprimées ne sont pas référencées.
- Par exemple, Spark 3.3.0 n'active pas Scala-Untyped UDFs, mais Spark 2.4 le permet.
- Toutes les tâches de la AWS Glue version 4.0 seront exécutées avec des temps de démarrage nettement améliorés. Les tâches Spark seront facturées par incréments d'une seconde avec une durée de facturation minimale 10 fois plus faible, puisque la latence de démarrage passera de 10 minutes maximum à 1 minute maximum.
- Le comportement de journalisation a changé de manière significative dans la AWS Glue version 4.0, la configuration minimale requise pour Spark 3.3.0 est Log4j2.
- Plusieurs mises à jour de dépendance, mises en évidence dans l'annexe.
- Scala est également mis à jour depuis la version 2.11 vers la version 2.12, et Scala 2.12 n'est pas rétrocompatible avec Scala 2.11.
- Python 3.10 est également la version utilisée par défaut pour les scripts Python, comme AWS Glue 0.9 utilisait uniquement Python 2.

Python 2.7 n'est pas pris en charge avec Spark 3.3.0. Toute tâche demandant Python 2 dans la configuration de la tâche échouera avec un `IllegalArgumentException`.

- Un nouveau mécanisme d'installation de modules Python supplémentaires via pip est disponible depuis la AWS Glue version 2.0. Pour plus d'informations, consultez [Installing additional Python modules with pip in AWS Glue 2.0+](#).
- AWS Glue La version 4.0 ne s'exécute pas sur Apache YARN, les paramètres YARN ne s'appliquent donc pas.
- AWS Glue La version 4.0 ne possède pas de système de fichiers distribué Hadoop (HDFS).
- Tout fichier JAR supplémentaire fourni dans les tâches AWS Glue 1.0 existantes peut entraîner des dépendances conflictuelles car plusieurs dépendances ont été mises à niveau dans la version 4.0 par rapport à la version 1.0. Pour éviter ce problème, nous activons la AWS Glue version 4.0 avec le paramètre `--user-jars-first` AWS Glue job par défaut.

- AWS Glue La version 4.0 prend en charge la mise à l'échelle automatique. Par conséquent, la `ExecutorAllocationManager` métrique sera disponible lorsque la mise à l'échelle automatique sera activée.
- Dans les tâches de la AWS Glue version 4.0, vous spécifiez le nombre de travailleurs et le type de travailleur, mais vous ne spécifiez pas `deMaxCapacity`.
- AWS Glue La version 4.0 ne prend pas encore en charge les transformations du machine learning.
- Pour la migration de certains connecteurs, consultez [Migration du connecteur et du pilote JDBC pour la version 4.0 AWS Glue](#).
- Le SDK de AWS chiffrement est mis à niveau de la version 1.x à la version 2.x. AWS Glue les tâches utilisant des configurations AWS Glue de sécurité et les tâches dépendantes de la dépendance du SDK de AWS chiffrement fournie lors de l'exécution sont affectées. Consultez ces instructions pour la migration des AWS Glue tâches.
 - Vous ne pouvez pas migrer AWS Glue directement une tâche 0.9/1.0 vers une tâche AWS Glue 4.0. En effet, lors de la mise à niveau directe vers la version 2.x ou ultérieure et de l'activation immédiate de toutes les nouvelles fonctionnalités, le SDK de AWS chiffrement ne sera pas en mesure de déchiffrer le texte chiffré dans les versions antérieures du SDK de chiffrement. AWS
 - Pour effectuer une mise à niveau en toute sécurité, nous vous recommandons d'abord de migrer vers une tâche AWS Glue 2.0/3.0 contenant la version pont du SDK AWS Encryption. Exécutez la tâche une fois pour utiliser la version pont du SDK de AWS chiffrement.
 - Une fois terminé, vous pouvez migrer en toute sécurité la tâche AWS Glue 2.0/3.0 vers AWS Glue la version 4.0.

Reportez-vous à la documentation sur la migration de Spark :

- [Upgrading from Spark SQL 2.4 to 3.0](#)
- [Upgrading from Spark SQL 3.0 to 3.1](#)
- [Upgrading from Spark SQL 3.1 to 3.2](#)
- [Upgrading from Spark SQL 3.2 to 3.3](#)
- [Changes in Datetime behavior to be expected since Spark 3.0.](#)

Migration de la version AWS Glue 0.9 à AWS Glue la version 4.0

Notez les modifications suivantes lors de la migration :

- AWS Glue La version 0.9 utilise le logiciel libre Spark 2.2.1 et la AWS Glue version 4.0 utilise Spark 3.3.0 optimisé pour Amazon EMR.
 - Plusieurs modifications Spark pourraient à elles seules nécessiter une révision de vos scripts pour s'assurer que les fonctions supprimées ne sont pas référencées.
 - Par exemple, Spark 3.3.0 n'active pas Scala-Untyped UDFs, mais Spark 2.2 le permet.
- Toutes les tâches de la AWS Glue version 4.0 seront exécutées avec des temps de démarrage nettement améliorés. Les tâches Spark seront facturées par incréments d'une seconde avec une durée de facturation minimale 10 fois plus faible, car la latence de démarrage passera de 10 minutes maximum à 1 minute maximum.
- Le comportement de journalisation a changé de manière significative depuis la AWS Glue version 4.0, Spark 3.3.0 requiert au minimum Log4j2, comme indiqué ici ([https://spark.apache.org/docs/latest/core-migration-guide.html# -32-to-33](https://spark.apache.org/docs/latest/core-migration-guide.html#-32-to-33)). upgrading-from-core
- Plusieurs mises à jour de dépendance, mises en évidence dans l'annexe.
- Scala est également mis à jour depuis la version 2.11 vers la version 2.12, et Scala 2.12 n'est pas rétrocompatible avec Scala 2.11.
- Python 3.10 est également la version utilisée par défaut pour les scripts Python, comme AWS Glue 0.9 utilisait uniquement Python 2.
 - Python 2.7 n'est pas pris en charge avec Spark 3.3.0. Toute tâche demandant Python 2 dans la configuration de la tâche échouera avec un `IllegalArgumentException`.
 - Un nouveau mécanisme d'installation de modules Python supplémentaires via pip est disponible.
- AWS Glue La version 4.0 ne s'exécute pas sur Apache YARN, les paramètres YARN ne s'appliquent donc pas.
- AWS Glue La version 4.0 ne possède pas de système de fichiers distribué Hadoop (HDFS).
- Tout fichier JAR supplémentaire fourni dans les tâches AWS Glue 0.9 existantes peut entraîner des dépendances conflictuelles car plusieurs dépendances ont été mises à niveau dans la version 3.0 par rapport à la version 0.9. Vous pouvez éviter les conflits de chemin de classe dans la AWS Glue version 3.0 avec le paramètre `--user-jars-first` AWS Glue job.
- AWS Glue La version 4.0 prend en charge la mise à l'échelle automatique. Par conséquent, la `ExecutorAllocationManager` métrique sera disponible lorsque la mise à l'échelle automatique sera activée.
- Dans les tâches de la AWS Glue version 4.0, vous spécifiez le nombre de travailleurs et le type de travailleur, mais vous ne spécifiez pas `demaxCapacity`.
- AWS Glue La version 4.0 ne prend pas encore en charge les transformations du machine learning.

- Pour la migration de certains connecteurs, consultez [Migration du connecteur et du pilote JDBC pour la version 4.0 AWS Glue](#).
- Le SDK de AWS chiffrement est mis à niveau de la version 1.x à la version 2.x. AWS Glue les tâches utilisant des configurations AWS Glue de sécurité et les tâches dépendantes de la dépendance du SDK de AWS chiffrement fournie lors de l'exécution sont affectées. Consultez ces instructions pour la migration des AWS Glue tâches.
- Vous ne pouvez pas migrer AWS Glue directement une tâche 0.9/1.0 vers une tâche AWS Glue 4.0. En effet, lors de la mise à niveau directe vers la version 2.x ou ultérieure et de l'activation immédiate de toutes les nouvelles fonctionnalités, le SDK de AWS chiffrement ne sera pas en mesure de déchiffrer le texte chiffré dans les versions antérieures du SDK de chiffrement. AWS
- Pour effectuer une mise à niveau en toute sécurité, nous vous recommandons d'abord de migrer vers une tâche AWS Glue 2.0/3.0 contenant la version pont du SDK AWS Encryption. Exécutez la tâche une fois pour utiliser la version pont du SDK de AWS chiffrement.
- Une fois terminé, vous pouvez migrer en toute sécurité la tâche AWS Glue 2.0/3.0 vers AWS Glue la version 4.0.

Reportez-vous à la documentation sur la migration de Spark :

- [Upgrading from Spark SQL 2.2 to 2.3](#)
- [Upgrading from Spark SQL 2.3 to 2.4](#)
- [Upgrading from Spark SQL 2.4 to 3.0](#)
- [Upgrading from Spark SQL 3.0 to 3.1](#)
- [Upgrading from Spark SQL 3.1 to 3.2](#)
- [Upgrading from Spark SQL 3.2 to 3.3](#)
- [Changes in Datetime behavior to be expected since Spark 3.0.](#)

Migration du connecteur et du pilote JDBC pour la version 4.0 AWS Glue

Pour en savoir plus sur les versions des connecteurs JDBC et de lac de données qui ont été mises à niveau, consultez :

- [Annexe B : Mises à niveau du pilote JDBC](#)
- [Annexe C : Mises à niveau des connecteurs](#)

Hudi

- Améliorations de la prise en charge de Spark SQL :
 - Cette commande `Call Procedure` permet de renforcer la prise en charge pour la mise à niveau, la rétrogradation, le démarrage, le nettoyage et la réparation. La syntaxe `Create/Drop/Show/Refresh Index` est autorisée dans Spark SQL.
 - Un écart de performance a été comblé entre les utilisations via Spark DataSource et Spark SQL. Dans le passé, les écritures Datasource étaient plus rapides qu'avec SQL.
 - Tous les générateurs de clés intégrés implémentent des opérations d'API spécifiques à Spark plus performantes.
 - Remplacement de la transformation UDF dans le cadre de l'insert opération en masse par des transformations RDD afin de réduire les coûts d'utilisation. `SerDe`
 - Spark SQL avec Hudi nécessite une `primaryKey` devant être spécifiée par `tblproperties` ou des options dans l'instruction SQL. Pour les opérations de mise à jour et de suppression, `preCombineField` est également obligatoire.
- Toute table Hudi créée avant la version 0.10.0 sans avoir besoin de recréer un `primaryKey` avec un champ `primaryKey` depuis la version 0.10.0.

PostgreSQL

- Plusieurs vulnérabilités (CVEs) ont été corrigées.
- Java 8 est pris en charge en mode natif.
- Si la tâche utilise des tableaux de tableaux, à l'exception des tableaux d'octets, ce scénario peut être traité sous forme de tableaux multidimensionnels.

MongoDB

- Le connecteur MongoDB actuel prend en charge Spark version 3.1 ou ultérieure et MongoDB version 4.0 ou ultérieure.
- En raison de la mise à niveau du connecteur, quelques noms de propriétés ont été modifiés. Par exemple, le nom de la propriété `URI` a été remplacé par `connection.uri`. Pour plus d'informations sur les options actuelles, consultez le [blog MongoDB Spark Connector](#).
- L'utilisation de MongoDB 4.0 hébergé par Amazon DocumentDB présente certaines différences fonctionnelles. Pour en savoir plus, consultez les rubriques suivantes :
 - [Différences fonctionnelles : Amazon DocumentDB et MongoDB](#)

- [MongoDB APIs, opérations et types de données pris en charge](#).
- L'option « partitionneur » est limitée à `ShardedPartitioner`, `PaginateIntoPartitionsPartitioner`, et `SinglePartitionPartitioner`. Elle ne peut pas utiliser les valeurs `SamplePartitioner` et `PaginateBySizePartitioner` par défaut pour Amazon DocumentDB, car l'opérateur de l'étape ne prend pas en charge l'API MongoDB. Pour plus d'informations, consultez [MongoDB APIs, Opérations et Types de données pris en charge](#).

Delta Lake

- Désormais, Delta Lake prend en charge les requêtes [Time Travel dans SQL](#) pour interroger facilement les données plus anciennes. Avec cette mise à jour, le voyage dans le temps est désormais disponible à la fois dans Spark SQL et via l' `DataFrame` API. La prise en charge de la version actuelle de `TIMESTAMP` dans SQL a été ajoutée.
- Spark 3.3 présente [Trigger. AvailableNow](#) pour exécuter des requêtes de streaming comme équivalent à `Trigger.Once` des requêtes par lots. Cette prise en charge est également disponible en cas d'utilisation des tables Delta comme source de streaming.
- Prise en charge de la fonction `SHOW COLUMNS` pour renvoyer la liste des colonnes d'une table.
- Support de [DESCRIBE DETAIL](#) dans les DeltaTable API Scala et Python. Il récupère des informations détaillées sur une table Delta à l'aide de l' `DeltaTable` API ou de Spark SQL.
- Prise en charge du renvoi de métriques d'opération à partir des commandes SQL [Delete](#), [Merge](#) et [Update](#). Auparavant, ces commandes SQL renvoyaient une valeur vide `DataFrame`, maintenant elles renvoient un `DataFrame` contenant des mesures utiles concernant l'opération effectuée.
- Pour optimiser les améliorations de performances :
 - Définissez l'option de configuration `spark.databricks.delta.optimize.repartition.enabled=true` de manière à utiliser `repartition(1)` plutôt que `coalesce(1)` dans la commande `Optimize` afin de bénéficier de meilleures performances lors du compactage de nombreux petits fichiers.
 - [Performances améliorées](#) grâce à une approche basée sur la file d'attente afin d'exécuter en parallèle les tâches de compactage.
- Autres changements notables :
 - [Prise en charge de l'utilisation de variables](#) dans les commandes SQL `VACUUM` et `OPTIMIZE`.
 - Améliorations apportées à `CONVERT TO DELTA` avec des tables de catalogue, notamment :
 - [Remplissez automatiquement le schéma de partition](#) à partir du catalogue s'il n'est pas fourni.

- [Utilisez les informations de partition](#) du catalogue pour rechercher les fichiers de données à valider au lieu d'effectuer une analyse complète du répertoire. Plutôt que de valider tous les fichiers de données du répertoire des tables, seuls les fichiers de données figurant dans les répertoires des partitions actives seront validés.
- [Prise en charge de la lecture par lots du flux CDF](#) sur les tables permettant le mappage de colonnes lorsque DROP COLUMN et RENAME COLUMN n'ont pas été utilisés. Pour plus d'informations, consultez la [documentation de Delta Lake](#).
- [Améliorez les performances de la commande Update](#) en activant le nettoyage du schéma dès le premier passage.

Apache Iceberg

- Ajout de plusieurs [améliorations des performances](#) pour la planification des scans et les requêtes Spark.
- Ajout d'un client de catalogue REST commun qui utilise des validations basées sur les modifications pour résoudre les conflits de validation côté service.
- La syntaxe AS OF des requêtes SQL Time Travel est prise en charge.
- Ajout merge-on-read du support pour les requêtes MERGE et UPDATE.
- Ajout de la prise en charge de la réécriture des partitions à l'aide de Z-order.
- Ajout d'une spécification et d'une implémentation pour Puffin, un format adapté aux statistiques volumineuses et aux blobs d'index, tels que les [esquisses Theta](#) ou les filtres Bloom.
- Ajout de nouvelles interfaces permettant de consommer les données par incréments (analyses des ajouts et du journal des modifications).
- Ajout de la prise en charge des opérations en bloc et des lectures par plage sur les interfaces FileIO.
- Ajout de tables de métadonnées supplémentaires pour afficher les fichiers supprimés dans l'arborescence des métadonnées.
- Le comportement de suppression de la table a changé. Dans Iceberg 0.13.1, l'exécution de DROP TABLE supprime la table du catalogue ainsi que le contenu de la table. Dans Iceberg 1.0.0, DROP TABLE supprime uniquement la table du catalogue. Pour supprimer le contenu de la table, utilisez DROP TABLE PURGE.
- Les lectures vectorisés Parquet sont activées par défaut dans Iceberg 1.0.0. Pour désactiver les lectures vectorisées, définissez `read.parquet.vectorization.enabled` sur `false`.

Oracle

Les modifications sont mineures.

MySQL

Les modifications sont mineures.

Amazon Redshift

AWS Glue La version 4.0 intègre un nouveau connecteur Amazon Redshift avec un nouveau pilote JDBC. Pour plus d'informations sur les améliorations et sur la façon de migrer depuis AWS Glue les versions précédentes, consultez [the section called “Connexions Redshift”](#).

Annexe A : Mises à niveau notables des dépendances

Voici les mises à niveau des dépendances :

Dépendance	Version en AWS Glue 4.0	Version en AWS Glue 3.0	Version en AWS Glue 2.0	Version en AWS Glue 1.0
Spark	3.3.0-amzn-1	3.1.1-amzn-0	2.4.3	2.4.3
Hadoop	3.3.3-amzn-0	3.2.1-amzn-3	2.8.5-amzn-5	2.8.5-amzn-1
Scala	2,12	2,12	2.11	2.11
Jackson	2.13.3	2.10.x	2.7.x	2.7.x
Hive	2.3.9-amzn-2	2.3.7-amzn-4	1.2	1.2
EMRFS	2,54,0	2,46,0	2.38.0	2.30.0
Json4s	3.7.0-M11	3.6.6	3.5.x	3.5.x
Flèche	7.0.0	2.0.0	0.10.0	0.10.0
AWS Glue Client de catalogue de données	3.7.0	3.0.0	1.10.0	N/A
Python	3,10	3.7	2.7 et 3.6	2.7 et 3.6

Dépendance	Version en AWS Glue 4.0	Version en AWS Glue 3.0	Version en AWS Glue 2.0	Version en AWS Glue 1.0
Boto	1,26	1,18	1.12	N/A

Annexe B : Mises à niveau du pilote JDBC

Voici les mises à niveau du pilote JDBC :

Pilote	Version du pilote JDBC dans les versions précédentes AWS Glue	Version du pilote JDBC en 3.0 AWS Glue	Version du pilote JDBC en 4.0 AWS Glue
MySQL	5.1	8.0.23	8.0.23
Microsoft SQL Server	6.1.0	7.0.0	9.4.0
Oracle Databases	11.2	21,1	21,7
PostgreSQL	42,10	42,2,18	42,3.6
MongoDB	2.0.0	4.0.0	4.7.2
Amazon Redshift	redshift-jdbc41-1.2.12.1017	redshift-jdbc41-1.2.12.1017	redshift-jdbc42-2.1.0.16

Annexe C : Mises à niveau des connecteurs

Les mises à niveau des connecteurs sont les suivantes :


Pilote	Version du connecteur en AWS Glue 3.0	Version du connecteur en AWS Glue 4.0
MongoDB	3.0.0	10,0.4
Hudi	0,1,1	0.12.1

Pilote	Version du connecteur en AWS Glue 3.0	Version du connecteur en AWS Glue 4.0
Delta Lake	1.0.0	2.1.0
Iceberg	0.13.1	1.0.0
DynamoDB	1.11	1.12

Améliorations génératives de l'IA pour Apache Spark in AWS Glue

Les mises à niveau génératives de l'IA pour la version préliminaire d'Apache Spark sont disponibles pour les versions 4.0 et 5.0 de AWS Glue dans les AWS régions suivantes : USA Est (Ohio), USA Est (Virginie du Nord), USA Ouest (Oregon), Asie-Pacifique (Tokyo) et Asie-Pacifique (Sydney). Les fonctionnalités de prévisualisation sont susceptibles d'être modifiées.

Spark Upgrades in AWS Glue permet aux ingénieurs de données et aux développeurs de mettre à niveau et de migrer leurs tâches AWS Glue Spark existantes vers les dernières versions de Spark à l'aide de l'IA générative. Les ingénieurs de données peuvent l'utiliser pour scanner leurs tâches AWS Glue Spark, générer des plans de mise à niveau, exécuter des plans et valider les résultats. Il réduit le temps et le coût des mises à niveau de Spark en automatisant le travail indifférencié d'identification et de mise à jour des scripts, des configurations, des dépendances, des méthodes et des fonctionnalités de Spark.



Comment ça marche

Lorsque vous utilisez l'analyse des mises à niveau, AWS Glue identifie les différences entre les versions et les configurations dans le code de votre tâche afin de générer un plan de mise à niveau. Le plan de mise à niveau détaille toutes les modifications du code et les étapes de migration requises. Ensuite, AWS Glue crée et exécute l'application mise à niveau dans un environnement pour valider les modifications et génère une liste de modifications de code afin que vous puissiez migrer votre travail. Vous pouvez consulter le script mis à jour ainsi que le résumé détaillant les modifications proposées. Après avoir effectué vos propres tests, acceptez les modifications et le job AWS Glue sera automatiquement mis à jour vers la dernière version avec le nouveau script.

Le processus d'analyse des mises à niveau peut prendre un certain temps, en fonction de la complexité de la tâche et de la charge de travail. Les résultats de l'analyse de mise à niveau seront stockés dans le chemin Amazon S3 spécifié, qui pourra être consulté pour comprendre la mise à niveau et les éventuels problèmes de compatibilité. Après avoir examiné les résultats de l'analyse de mise à niveau, vous pouvez décider de poursuivre la mise à niveau proprement dite ou d'apporter les modifications nécessaires à la tâche avant la mise à niveau.

Prérequis

Les prérequis suivants sont requis pour utiliser l'IA générative afin de mettre à niveau les jobs dans AWS Glue :

- **AWS Tâches Glue 2 PySpark** : seules les tâches AWS Glue 2 peuvent être mises à niveau vers AWS Glue 5.
- Les autorisations IAM sont nécessaires pour démarrer l'analyse, examiner les résultats et améliorer votre tâche. Pour plus d'informations, consultez les exemples présentés dans la [Autorisations](#) section ci-dessous.
- Si vous l'utilisez AWS KMS pour chiffrer des artefacts d'analyse ou un service pour chiffrer les données utilisées pour l'analyse, des AWS KMS autorisations supplémentaires sont nécessaires. Pour plus d'informations, consultez les exemples présentés dans la [AWS KMS politique](#) section ci-dessous.

Autorisations

Pour démarrer une nouvelle analyse de mise à niveau, vous devez disposer des autorisations suivantes :

1. Mettez à jour la politique IAM de l'appelant avec l'autorisation suivante :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:StartJobUpgradeAnalysis",
        "glue:StartJobRun",
        "glue:GetJobRun",
        "glue:GetJob",
        "glue:BatchStopJobRun"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:123456789012:job/jobName"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ],
```



```

    "Resource": [
      "<s3 script location associated with the job>"
    ],
  },
  {
    "Effect": "Allow",
    "Action": ["s3:PutObject"],
    "Resource": [
      "<result s3 path provided on API>"
    ],
  },
  {
    "Effect": "Allow",
    "Action": [
      "kms:Decrypt",
      "kms:GenerateDataKey",
    ],
    "Resource": "<key-arn-passed in the API>"
  }
]
}

```

Note

Si vous utilisez deux AWS KMS clés différentes, l'une pour le chiffrement des artefacts de résultat et l'autre pour le chiffrement des métadonnées de service, la politique doit inclure une politique similaire pour les deux clés.

2. Mettez à jour le rôle d'exécution de la tâche que vous mettez à niveau pour inclure la politique en ligne suivante :

```

{
  "Effect": "Allow",
  "Action": ["s3:GetObject"],
  "Resource": [
    "ARN of the Amazon S3 path provided on API",
    "ARN of the Amazon S3 path provided on API/*"
  ]
}

```

Par exemple, si vous utilisez le chemin Amazon S3 `s3://amzn-s3-demo-bucket/upgraded-result`, la politique sera la suivante :

```
{
  "Effect": "Allow",
  "Action": ["s3:GetObject"],
  "Resource": [
    "arn:aws:s3:::amzn-s3-demo-bucket/upgraded-result/",
    "arn:aws:s3:::amzn-s3-demo-bucket/upgraded-result/*"
  ]
}
```

Pour récupérer les détails d'une analyse, vous devez disposer des autorisations suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": ["glue:GetJobUpgradeAnalysis"],
      "Resource": [
        "arn:aws:glue:us-east-1:123456789012:job/jobName"
      ]
    }
  ]
}
```

Pour arrêter une analyse en cours, vous devez disposer des autorisations suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": ["glue:StopJobUpgradeAnalysis",
        "glue:BatchStopJobRun"],
      "Resource": [
        "arn:aws:glue:us-east-1:123456789012:job/jobName"
      ]
    }
  ]
}
```

```
]
}
```

Pour répertorier toutes les analyses soumises dans le cadre d'une tâche spécifique, vous devez disposer des autorisations suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": ["glue:ListJobUpgradeAnalyses"],
      "Resource": [
        "arn:aws:glue:us-east-1:123456789012:job/jobName"
      ]
    }
  ]
}
```

Pour accepter les modifications apportées par une analyse et mettre à niveau une tâche, vous devez disposer des autorisations suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": ["glue:UpdateJob",
        "glue:UpgradeJob"],
      "Resource": [
        "arn:aws:glue:us-east-1:123456789012:job/jobName"
      ]
    },
    {
      "Effect": "Allow",
      "Action": ["iam:PassRole"],
      "Resource": [
        "<Role arn associated with the job>"
      ]
    }
  ]
}
```

```
}
```

AWS KMS politique

Pour transmettre votre propre AWS KMS clé personnalisée lors du démarrage d'une analyse, reportez-vous à la section suivante pour configurer les autorisations appropriées sur les AWS KMS clés.

Configuration de la AWS KMS clé de chiffrement des métadonnées du service :

Vous devez disposer d'une autorisation (chiffrement/déchiffrer) pour transmettre la clé. Dans l'exemple de politique ci-dessous, le AWS compte ou le rôle spécifié par le <IAM Customer caller ARN> est autorisé à effectuer les actions autorisées :

- KMS:Decrypt permet le déchiffrement à l'aide de la clé spécifiée. AWS KMS
- kms : GenerateDataKey permet de générer une clé de données à l'aide de la AWS KMS clé spécifiée.

```
{
  "Effect": "Allow",
  "Principal":{
    "AWS": "<IAM Customer caller ARN>"
  },
  "Action": [
    "kms:Decrypt",
    "kms:GenerateDataKey",
  ],
  "Resource": "<key-arn-passed-on-start-api>"
}
```

Vous devez autoriser AWS Glue à utiliser la AWS KMS clé à la fois pour le chiffrement et le déchiffrement de la clé.

```
{
  "Effect": "Allow",
  "Principal":{
    "Service": "glue.amazonaws.com"
  },
  "Action": [
    "kms:Decrypt",
  ],
}
```

```

    "kms:GenerateDataKey",
  ],
  "Resource": "<key-arn>",
  "Condition": {
    "StringLike": {
      "aws:SourceArn": "arn:aws:glue:<region>:<aws_account_id>:job/job-name"
    }
  }
}

```

Configuration du chiffrement de l'artefact obtenu à l'aide d'une AWS KMS clé :

Cette politique garantit que vous disposez à la fois des autorisations de chiffrement et de déchiffrement sur la AWS KMS clé.

```

{
  "Effect": "Allow",
  "Principal": {
    "AWS": "<IAM Customer caller ARN>"
  },
  "Action": [
    "kms:Decrypt",
    "kms:GenerateDataKey",
  ],
  "Resource": "<key-arn-passed-on-start-api>"
}

```

Exécution d'une analyse de mise à niveau et application du script de mise à niveau

Vous pouvez exécuter une analyse de mise à niveau, qui générera un plan de mise à niveau pour une tâche que vous sélectionnez dans la vue Tâches.

1. Dans Jobs, sélectionnez une tâche AWS Glue 2.0, puis choisissez Run upgrade analysis dans le menu Actions.

AWS Glue Studio [Info](#)Create job [Info](#)

Author in a visual interface focused on data flow.

Visual ETL



Author using an interactive code notebook.

Notebook



Author code with a script editor.

Script editor

▶ Example jobs [Info](#)[Create example job](#)Your jobs (3) [Info](#)

Q Filter jobs by property

3 matches

glue2 X

[Clear filters](#)

☐	Job name	Type	Created by	Last modified
☐	glue2-migrate-demo	Glue ETL	Script	11/6/2024, 2:14:49 AM
☐	glue2-migration	Glue ETL	Script	11/4/2024, 9:56:12 PM
☒	glue2-count	Glue ETL	Script	11/1/2024, 12:51:39 AM

- ⌂ Actions ⬆ [Run job](#)
- Edit job

Clone job


Schedule job

Delete job(s)

Reset job bookmark

🚀 Run upgrade analysis with AI - preview
- 1 > ⚙

2. Dans le modal, sélectionnez un chemin pour stocker votre plan de mise à niveau généré dans le chemin des résultats. Il doit s'agir d'un compartiment Amazon S3 auquel vous pouvez accéder et dans lequel vous pouvez écrire.



3. Configurez des options supplémentaires, si nécessaire :

- **Configuration d'exécution** : facultative : La configuration d'exécution est un paramètre facultatif qui vous permet de personnaliser divers aspects des exécutions de validation effectuées lors de l'analyse de mise à niveau. Cette configuration est utilisée pour exécuter le script mis à niveau et vous permet de sélectionner les propriétés de l'environnement de calcul (type de travailleur, nombre de travailleurs, etc.). Notez que vous devez utiliser vos comptes de développeur hors production pour exécuter les validations sur des exemples de jeux de données avant de vérifier, d'accepter les modifications et de les appliquer aux environnements de production. La configuration d'exécution inclut les paramètres personnalisables suivants :
- **Type de travailleur** : vous pouvez spécifier le type de travailleur à utiliser pour les cycles de validation, ce qui vous permet de choisir les ressources de calcul appropriées en fonction de vos besoins.

- Nombre de travailleurs : vous pouvez définir le nombre de travailleurs à affecter pour les cycles de validation, ce qui vous permet d'adapter les ressources en fonction de vos besoins en matière de charge de travail.
- Délai d'expiration des tâches (en minutes) : ce paramètre vous permet de définir une limite de temps pour les cycles de validation, en veillant à ce que les tâches se terminent après une durée spécifiée afin d'éviter une consommation excessive de ressources.
- Configuration de la sécurité : vous pouvez configurer les paramètres de sécurité, tels que le chiffrement et le contrôle d'accès, pour garantir la protection de vos données et de vos ressources pendant les cycles de validation.
- Paramètres de tâche supplémentaires : si nécessaire, vous pouvez ajouter de nouveaux paramètres de tâche afin de personnaliser davantage l'environnement d'exécution pour les cycles de validation.

En tirant parti de la configuration d'exécution, vous pouvez adapter les cycles de validation à vos besoins spécifiques. Par exemple, vous pouvez configurer les cycles de validation pour utiliser un ensemble de données plus petit, ce qui permet d'effectuer l'analyse plus rapidement et d'optimiser les coûts. Cette approche garantit que l'analyse de mise à niveau est effectuée efficacement tout en minimisant l'utilisation des ressources et les coûts associés pendant la phase de validation.

- Configuration du chiffrement — optionnelle :
 - Activer le chiffrement des artefacts de mise à niveau : activez le chiffrement au repos lorsque vous écrivez des données dans le chemin des résultats. Si vous ne souhaitez pas chiffrer vos artefacts de mise à niveau, laissez cette option décochée.
 - Personnalisez le chiffrement des métadonnées de service : les métadonnées de vos services sont chiffrées par défaut AWS à l'aide de clés détenues. Choisissez cette option si vous souhaitez utiliser votre propre clé pour le chiffrement.
4. Choisissez Exécuter pour démarrer l'analyse de mise à niveau. Pendant que l'analyse est en cours, vous pouvez consulter les résultats dans l'onglet Analyse de mise à niveau. La fenêtre des détails de l'analyse affiche des informations sur l'analyse ainsi que des liens vers les artefacts de mise à niveau.
- Chemin du résultat : c'est là que le résumé des résultats et le script de mise à niveau sont stockés.
 - Script mis à niveau dans Amazon S3 : emplacement du script de mise à niveau dans Amazon S3. Vous pouvez consulter le script avant d'appliquer la mise à niveau.

- Résumé de la mise à niveau dans Amazon S3 : emplacement du résumé de la mise à niveau dans Amazon S3. Vous pouvez consulter le résumé de la mise à niveau avant d'appliquer la mise à niveau.
5. Lorsque l'analyse de mise à niveau est terminée avec succès, vous pouvez appliquer le script de mise à niveau pour mettre automatiquement à niveau votre tâche en choisissant Appliquer le script mis à niveau.

Une fois appliquée, la version AWS Glue sera mise à jour vers la version 4.0. Vous pouvez consulter le nouveau script dans l'onglet Script.

Glue-upgrades-demo-job

Last modified on 2024-11-14, 11:38:18 a.m.

Load JSON

Dev Utils

Actions

Save

Run

Script

Job details

Runs

Data quality

Schedules

Version Control

Upgrade analysis - preview

Analysis (1/1)

Last updated (UTC) November 21, 2024 at 21:14:11

Stop

Filter upgrade analysis by property

Analysis ID	Status	Target Glue version	Start time	End time	Duration
ja-c6104a89-e3cf-487f-b8d0-61340b570914	Succeeded	4.0	11/12/2024 17:29:14	11/12/2024 17:35:02	5 m 48 s

Analysis details

The analysis completed successfully. You can apply the changes to your script now.

Apply upgraded script

Analysis ID

ja-c6104a89-e3cf-487f-b8d0-61340b570914

Completion time

11/12/2024 17:35:02

Result path

s3://aws-glue-scripts-us-east-1-gamma/E2ETests/AfterScripts/EZE-Demo/

Status

Succeeded

Start time

11/12/2024 17:29:14

Upgraded script in S3

s3://aws-glue-scripts-us-east-1-gamma/E2ETests/AfterScripts/ja-c6104a89-e3cf-487f-b8d0-61340b570914/EZE-Demo.py

Error message

-

Associated validation job runs

analysis_job_run_attempt0
analysis_job_run_attempt1
analysis_job_run_attempt2

Upgraded summary in S3

s3://aws-glue-scripts-us-east-1-gamma/E2ETests/AfterScripts/ja-c6104a89-e3cf-487f-b8d0-61340b570914/summary/summary.txt

Comprendre le résumé de votre mise à niveau

Cet exemple illustre le processus de mise à niveau d'une tâche AWS Glue de la version 2.0 à la version 4.0. L'exemple de tâche lit les données du produit depuis un compartiment Amazon S3, applique plusieurs transformations aux données à l'aide de Spark SQL, puis enregistre les résultats transformés dans un compartiment Amazon S3.

Code original (AWS Glue 2.0) - avant la mise à niveau

```
from awsglue.transforms import *
from pyspark.context import SparkContext
```

```
from awsglue.context import GlueContext
from pyspark.sql.types import *
from pyspark.sql.functions import *
from awsglue.job import Job
import json
from pyspark.sql.types import StructType

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)

gdc_database = "s3://aws-glue-scripts-us-east-1-gamma/demo-database/"
schema_location = (
    "s3://aws-glue-scripts-us-east-1-gamma/DataFiles/"
)

products_schema_string = spark.read.text(
    f"{schema_location}schemas/products_schema"
).first()[0]

product_schema = StructType.fromJson(json.loads(products_schema_string))

products_source_df = (
    spark.read.option("header", "true")
    .schema(product_schema)
    .option(
        "path",
        f"{gdc_database}products/",
    )
    .csv(f"{gdc_database}products/")
)

products_source_df.show()
products_temp_view_name = "spark_upgrade_demo_product_view"
products_source_df.createOrReplaceTempView(products_temp_view_name)

query = f"select {products_temp_view_name}.*, format_string('%0$s-%0$s', category,
    subcategory) as unique_category from {products_temp_view_name}"
products_with_combination_df = spark.sql(query)
products_with_combination_df.show()

products_with_combination_df.createOrReplaceTempView(products_temp_view_name)
product_df_attribution = spark.sql(
```

```

        f"""
SELECT *,
unbase64(split(product_name, ' ')[0]) as product_name_decoded,
unbase64(split(unique_category, '-')[1]) as subcategory_decoded
FROM {products_temp_view_name}
"""
    )
    product_df_attribution.show()

    product_df_attribution.write.mode("overwrite").option("header", "true").option(
        "path", f"{gdc_database}spark_upgrade_demo_product_agg/"
    ).saveAsTable("spark_upgrade_demo_product_agg", external=True)

    spark_upgrade_demo_product_agg_table_df = spark.sql(
        f"SHOW TABLE EXTENDED in default like 'spark_upgrade_demo_product_agg'"
    )
    spark_upgrade_demo_product_agg_table_df.show()
    job.commit()

```

Nouveau code (Glue 4.0) - après la mise à niveau

```

from awsglue.transforms import *
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from pyspark.sql.types import *
from pyspark.sql.functions import *
from awsglue.job import Job
import json
from pyspark.sql.types import StructType

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
# change 1
spark.conf.set("spark.sql.adaptive.enabled", "false")
# change 2
spark.conf.set("spark.sql.legacy.pathOptionBehavior.enabled", "true")
job = Job(glueContext)

gdc_database = "s3://aws-glue-scripts-us-east-1-gamma/demo-database/"
schema_location = (
    "s3://aws-glue-scripts-us-east-1-gamma/DataFiles/"

```

```

)

products_schema_string = spark.read.text(
    f"{schema_location}schemas/products_schema"
).first()[0]

product_schema = StructType.fromJson(json.loads(products_schema_string))

products_source_df = (
    spark.read.option("header", "true")
    .schema(product_schema)
    .option(
        "path",
        f"{gdc_database}products/",
    )
    .csv(f"{gdc_database}products/")
)

products_source_df.show()
products_temp_view_name = "spark_upgrade_demo_product_view"
products_source_df.createOrReplaceTempView(products_temp_view_name)

# change 3
query = f"select {products_temp_view_name}.*, format_string('%1$s-%1$s', category,
    subcategory) as unique_category from {products_temp_view_name}"
products_with_combination_df = spark.sql(query)
products_with_combination_df.show()

products_with_combination_df.createOrReplaceTempView(products_temp_view_name)
# change 4
product_df_attribution = spark.sql(
    f"""
SELECT *,
try_to_binary(split(product_name, ' ')[0], 'base64') as product_name_decoded,
try_to_binary(split(unique_category, '-')[1], 'base64') as subcategory_decoded
FROM {products_temp_view_name}
"""
)
product_df_attribution.show()

product_df_attribution.write.mode("overwrite").option("header", "true").option(
    "path", f"{gdc_database}spark_upgrade_demo_product_agg/"
).saveAsTable("spark_upgrade_demo_product_agg", external=True)

```

```
spark_upgrade_demo_product_agg_table_df = spark.sql(  
    f"SHOW TABLE EXTENDED in default like 'spark_upgrade_demo_product_agg'"  
)  
spark_upgrade_demo_product_agg_table_df.show()  
job.commit()
```

Explication du résumé de l'analyse

In Spark 3.2, `spark.sql.adaptive.enabled` is enabled by default. To restore the behavior before Spark 3.2, you can set `spark.sql.adaptive.enabled` to `false`.

In Spark 3.1, `path` option cannot coexist when the following methods are called with `path` parameter(s): `DataFrameReader.load()`, `DataFrameWriter.save()`, `DataStreamReader.load()`, or `DataStreamWriter.start()`. In addition, `paths` option cannot coexist for `DataFrameReader.load()`. For example, `spark.read.format(csv).option(path, /tmp).load(/tmp2)` or `spark.read.option(path, /tmp).csv(/tmp2)` will throw `org.apache.spark.sql.AnalysisException`. In Spark version 3.0 and below, `path` option is overwritten if one `path` parameter is passed to above methods; `path` option is added to the overall `paths` if multiple `path` parameters are passed to `DataFrameReader.load()`. To restore the behavior before Spark 3.1, you can set `spark.sql.legacy.pathOptionBehavior.enabled` to `true`.

Since Spark 3.3, the ``strfmt`` in ``format_string(strfmt, obj, ...)`` and ``printf(strfmt, obj, ...)`` will no longer support to use `0$` to specify the first argument, the first argument should always reference by `1$` when use argument index to indicating the position of the argument in the argument list.

Since Spark 3.3, the `unbase64` function throws error for a malformed `str` input. Use `try_to_binary(<str>, 'base64')` to tolerate malformed input and return `NULL` instead. In Spark 3.2 and earlier, the `unbase64` function returns a best-efforts result for a malformed `str` input.

Sur la base du résumé, quatre modifications ont été proposées par AWS Glue afin de réussir la mise à niveau du script de AWS Glue 2.0 vers AWS Glue 4.0 :

1. Configuration Spark SQL (`spark.sql.adaptive.enabled`) : cette modification vise à restaurer le comportement de l'application car une nouvelle fonctionnalité d'exécution de requêtes adaptatives Spark SQL est introduite à partir de Spark 3.2. Vous pouvez inspecter cette modification de configuration et l'activer ou la désactiver selon leurs préférences.
2. DataFrame Modification de l'API : l'option `path` ne peut pas coexister avec d'autres `DataFrameReader` opérations telles que `load()`. Pour conserver le comportement précédent, AWS Glue a mis à jour le script pour ajouter une nouvelle configuration SQL (`spark.sql.legacy.pathOptionBehavior` activé).

3. Modification de l'API Spark SQL : le comportement de `strfmt` in `format_string(strfmt, obj, ...)` a été mis à jour pour être interdit `0$` comme premier argument. Pour garantir la compatibilité, AWS Glue a modifié le script pour l'utiliser `1$` comme premier argument à la place.
4. Modification de l'API Spark SQL : la `unbase64` fonction n'autorise pas les entrées de chaîne mal formées. Pour conserver le comportement précédent, AWS Glue a mis à jour le script afin d'utiliser la `try_to_binary` fonction.

Arrêt d'une analyse de mise à niveau en cours

Vous pouvez annuler une analyse de mise à niveau en cours ou simplement arrêter l'analyse.

1. Choisissez l'onglet Upgrade Analysis.
2. Sélectionnez le job en cours d'exécution, puis choisissez Stop. Cela arrêtera l'analyse. Vous pouvez ensuite exécuter une autre analyse de mise à niveau sur la même tâche.

glue2-migrate-demo Last modified on 11/5/2024, 2:11:50 PM Load JSON Dev Utils Actions Save Run

Script Job details Runs Data quality Schedules Version Control Upgrade Analysis - preview

Analysis (1/1) Last updated (UTC) November 5, 2024 at 05:16:02 Stop

Filter upgrade analysis by property

Analysis ID	Status	Target Glue version	Start time (Local)	End time (Local)	Duration
ja-254c2a32-7fa6-48a3-a93c-62bb110a74b9	Running	4.0	11/05/2024 14:14:06		1 m 56 s

Considérations

Lorsque vous commencez à utiliser Spark Upgrades pendant la période de prévisualisation, plusieurs aspects importants doivent être pris en compte pour une utilisation optimale du service.

- Étendue et limites du service : La version préliminaire se concentre sur les mises à niveau du PySpark code depuis les versions 2.0 vers la version 5.0 de AWS Glue. À l'heure actuelle, le service gère le PySpark code qui ne repose pas sur des dépendances de bibliothèque supplémentaires. Vous pouvez exécuter des mises à niveau automatisées pour un maximum de 10 tâches simultanément dans un AWS compte, ce qui vous permet de mettre à niveau efficacement plusieurs tâches tout en préservant la stabilité du système.
- Seuls les PySpark emplois sont pris en charge.
- L'analyse de la mise à niveau expirera au bout de 24 heures.

- Une seule analyse de mise à niveau active peut être exécutée à la fois pour une tâche. Au niveau du compte, jusqu'à 10 analyses de mise à niveau actives peuvent être exécutées simultanément.
- Optimisation des coûts pendant le processus de mise à niveau : étant donné que Spark Upgrades utilise l'IA générative pour valider le plan de mise à niveau par le biais de plusieurs itérations, chaque itération étant exécutée sous forme de tâche AWS Glue dans votre compte, il est essentiel d'optimiser les configurations d'exécution des tâches de validation pour des raisons de rentabilité. Pour ce faire, nous vous recommandons de spécifier une configuration d'exécution lors du lancement d'une analyse de mise à niveau comme suit :
 - Utilisez des comptes de développeur hors production et sélectionnez des exemples de jeux de données fictifs qui représentent vos données de production mais dont la taille est plus petite pour la validation avec Spark Upgrades.
 - Utilisez des ressources de calcul correctement dimensionnées, telles que des travailleurs G1X, et sélectionnez un nombre approprié de travailleurs pour traiter vos échantillons de données.
 - Activation de l'auto-scaling des tâches AWS Glue, le cas échéant, pour ajuster automatiquement les ressources en fonction de la charge de travail.

Par exemple, si votre tâche de production traite des téraoctets de données avec 20 travailleurs G.2X, vous pouvez configurer la tâche de mise à niveau pour traiter quelques gigaoctets de données représentatives avec 2 opérateurs G.2X et activer l'auto-scaling pour la validation.

- Meilleures pratiques en matière de prévisualisation : pendant la période de prévisualisation, nous vous recommandons vivement de commencer votre processus de mise à niveau par des tâches non liées à la production. Cette approche vous permet de vous familiariser avec le flux de mise à niveau et de comprendre comment le service gère les différents types de modèles de code Spark.
- Alarmes et notifications : lorsque vous utilisez la fonction de mise à niveau de l'IA générative sur une tâche, assurez-vous que les alarmes/notifications en cas d'échec de l'exécution des tâches sont désactivées. Au cours du processus de mise à niveau, il se peut que jusqu'à 10 tâches aient échoué sur votre compte avant que les artefacts mis à niveau ne soient fournis.
- Règles de détection des anomalies : désactivez également les règles de détection des anomalies sur le Job en cours de mise à niveau, car les données écrites dans les dossiers de sortie lors des exécutions de tâches intermédiaires risquent de ne pas être au format attendu pendant la validation de la mise à niveau.
- Utiliser l'analyse de mise à niveau avec les tâches idempotentes : utilisez l'analyse de mise à niveau avec les tâches idempotentes pour vous assurer que chaque tentative d'exécution de tâche de validation suivante est similaire à la précédente et ne présente aucun problème. Les tâches

idempotentes sont des tâches qui peuvent être exécutées plusieurs fois avec les mêmes données d'entrée et qui produiront le même résultat à chaque fois. Lorsque vous utilisez les mises à niveau de Generative AI pour Apache Spark in AWS Glue, le service exécutera plusieurs itérations de votre tâche dans le cadre du processus de validation. Au cours de chaque itération, il apportera des modifications à votre code et à vos configurations Spark afin de valider le plan de mise à niveau. Si votre tâche Spark n'est pas idempotente, l'exécuter plusieurs fois avec les mêmes données d'entrée peut entraîner des problèmes.

Inférence entre régions dans Spark Upgrades

Spark Upgrades est alimenté par Amazon Bedrock et exploite l'inférence interrégionale (CRIS). Avec CRIS, Spark Upgrades sélectionne automatiquement la région optimale au sein de votre zone géographique (comme décrit plus en détail [ici](#)) pour traiter votre demande d'inférence, optimiser les ressources de calcul disponibles et la disponibilité des modèles, et offrir la meilleure expérience client. L'utilisation de l'inférence interrégionale n'entraîne aucun coût supplémentaire.

Les demandes d'inférence interrégionales sont conservées dans les AWS régions qui font partie de la zone géographique dans laquelle les données se trouvent à l'origine. Par exemple, une demande faite aux États-Unis est conservée dans les AWS régions des États-Unis. Bien que les données restent stockées uniquement dans la région principale, lorsque vous utilisez l'inférence entre régions, vos invites de saisie et les résultats de sortie peuvent être déplacés en dehors de votre région principale. Toutes les données seront transmises cryptées sur le réseau sécurisé d'Amazon.

Utilisation des jobs Spark dans AWS Glue

Fournit des informations sur AWS Glue les tâches ETL de Spark.

Rubriques

- [Utilisation des paramètres des tâches dans les tâches AWS Glue](#)
- [AWS Glue Spark et PySpark jobs](#)
- [Diffusion de jobs ETL dans AWS Glue](#)
- [Record correspondant à AWS Lake Formation FindMatches](#)
- [Migrer les programmes Apache Spark vers AWS Glue](#)

Utilisation des paramètres des tâches dans les tâches AWS Glue

Lorsque vous créez une tâche AWS Glue, vous définissez des champs standard, tels que `Role` et `WorkerType`. Vous pouvez fournir des informations de configuration supplémentaires par le biais des champs `Argument` (Paramètres de la tâche dans la console). Dans ces champs, vous pouvez fournir aux tâches AWS Glue les arguments (paramètres) répertoriés dans cette rubrique.

Pour plus d'informations sur l'API AWS Glue Job, consultez [the section called “Tâches”](#).

Note

La taille maximale des arguments Job est de 260 Ko. Une vérification de validation génère une erreur si la taille de l'argument est supérieure à 260 Ko.

Configuration des paramètres de tâche

Vous pouvez configurer une tâche via la console, dans les Détails de la tâche, sous l'en-tête Paramètres des tâches. Vous pouvez également configurer une tâche via le paramètre « AWS CLI en configurant » `DefaultArguments` ou `NonOverridableArguments` sur une tâche, ou en configurant `Arguments` l'exécution d'une tâche. Les arguments définis pour la tâche seront transmis à chaque exécution de la tâche, tandis que les arguments définis lors de l'exécution de la tâche ne seront transmis que pour cette exécution individuelle.

Par exemple, ce qui suit est la syntaxe pour exécuter une tâche en utilisant `--arguments` pour définir un paramètre de tâche.

```
$ aws glue start-job-run --job-name "CSV to CSV" --arguments='--scriptLocation="s3://my_glue/libraries/test_lib.py"'
```

Accès aux paramètres des tâches

Lorsque vous écrivez des scripts AWS Glue, vous souhaitez peut-être accéder aux valeurs des paramètres des tâches afin de modifier le comportement de votre propre code. Nous fournissons des méthodes d'aide pour ce faire dans nos bibliothèques. Ces méthodes résolvent les valeurs des paramètres d'exécution des tâches qui remplacent les valeurs des paramètres des tâches. Lors de la résolution de paramètres définis à plusieurs emplacements, la tâche `NonOverridableArguments`

remplacera les Arguments de l'exécution de la tâche, qui remplacera les DefaultArguments de la tâche.

Dans Python :

Dans les tâches Python, nous fournissons une fonction nommée `getResolvedParameters`. Pour de plus amples informations, veuillez consulter [the section called “getResolvedOptions”](#). Les paramètres de la tâche sont disponibles dans la variable `sys.argv`.

Dans Scala :

Dans les tâches Scala, nous fournissons un objet nommé `GlueArgParser`. Pour de plus amples informations, veuillez consulter [the section called “GlueArgParser”](#). Les paramètres de la tâche sont disponibles dans la variable `sysArgs`.

Référence des paramètres de la tâche

AWS Glue reconnaît les noms d'arguments suivants que vous pouvez utiliser pour configurer l'environnement de script pour vos tâches et leurs exécutions :

--additional-python-modules

une liste délimitée par des virgules représentant un ensemble de packages Python à installer. Vous pouvez installer des packages depuis PyPI ou fournir une distribution personnalisée. Une entrée de package PyPI sera au format `package==version`, avec le nom PyPI et la version de votre package cible. Une entrée de distribution personnalisée est le chemin S3 vers la distribution.

Les entrées utilisent la correspondance entre versions de Python pour faire correspondre le package et la version. Cela signifie que vous devrez utiliser deux signes d'égalité, comme `==`. Il existe d'autres opérateurs de correspondance de version. Pour plus d'informations, voir [PEP 440](#).

Pour transmettre les options d'installation du module à `pip3`, utilisez le paramètre [--python-modules-installer-option](#).

--auto-scale-within-microbatch

La valeur par défaut est `True`. Ce paramètre ne peut être utilisé que pour les tâches de streaming AWS Glue, qui traitent les données de streaming en une série de microlots, et le dimensionnement automatique doit être activé. Lorsque cette valeur est définie sur `false`, il calcule la moyenne mobile exponentielle de la durée du lot pour les microlots terminés et compare cette

valeur à la taille de la fenêtre pour déterminer s'il convient d'augmenter ou de réduire le nombre d'exécuteurs. La mise à l'échelle ne se produit que lorsqu'un microlot est terminé. Lorsque cette valeur est définie sur `true`, lors d'un microlot, elle augmente lorsque le nombre de tâches Spark reste le même pendant 30 secondes ou que le traitement par lots en cours est supérieur à la taille de la fenêtre. Le nombre d'exécuteurs diminuera si un exécuteur est inactif depuis plus de 60 secondes ou si la moyenne mobile exponentielle de la durée du lot est faible.

--class

La classe Scala qui sert de point d'entrée à votre script Scala. Cela s'applique uniquement si votre `--job-language` est défini sur `scala`.

--continuous-log-conversionPattern

Spécifie un modèle de journal de conversion personnalisé pour une tâche activée pour la journalisation en continu. Le modèle de conversion s'applique uniquement aux journaux des pilotes et des programmes d'exécution. Cela n'affecte pas la barre de progression de AWS Glue.

--continuous-log-logGroup

Spécifie un nom de groupe de CloudWatch journaux Amazon personnalisé pour une tâche activée pour la journalisation continue.

--continuous-log-logStreamPrefix

Spécifie un préfixe de flux de CloudWatch journal personnalisé pour une tâche activée pour la journalisation continue.

--customer-driver-env-vars et **--customer-executor-env-vars**

Ces paramètres définissent des variables d'environnement sur le système d'exploitation respectivement pour chaque travailleur (pilote ou exécuteur). Vous pouvez utiliser ces paramètres lorsque vous créez des plateformes et des frameworks personnalisés sur AWS Glue, afin de permettre à vos utilisateurs d'écrire des jobs dessus. L'activation de ces deux indicateurs vous permettra de définir des variables d'environnement différentes sur le pilote et sur l'exécuteur, respectivement, sans avoir à injecter la même logique dans le script de tâche lui-même.

Exemple d'utilisation

Voici un exemple d'utilisation de ces paramètres :

```
"--customer-driver-env-vars", "CUSTOMER_KEY1=VAL1,CUSTOMER_KEY2=\"val2, val2 val2\"",
```

```
"-customer-executor-env-vars", "CUSTOMER_KEY3=VAL3,KEY4=VAL4"
```

Les définir dans l'argument job run revient à exécuter les commandes suivantes :

Dans le pilote :

- exporter CUSTOMER_ = KEY1 VAL1
- export CUSTOMER_ KEY2 ="val2, val2 val2"

Dans l'exécuteur testamentaire :

- exporter CUSTOMER_ = KEY3 VAL3

Ensuite, dans le script de tâche lui-même, vous pouvez récupérer les variables d'environnement à l'aide de `os.environ.get("CUSTOMER_KEY1")` ou `System.getenv("CUSTOMER_KEY1")`.

Syntaxe appliquée

Respectez les normes suivantes lors de la définition des variables d'environnement :

- Chaque clé doit avoir le `CUSTOMER_` prefix.

Par exemple : for "CUSTOMER_KEY3=VAL3,KEY4=VAL4", KEY4=VAL4 sera ignoré et ne sera pas défini.

- Chaque paire clé/valeur doit être délimitée par une simple virgule.

Par exemple : "CUSTOMER_KEY3=VAL3,CUSTOMER_KEY4=VAL4"

- Si la « valeur » comporte des espaces ou des virgules, elle doit être définie entre guillemets.

Par exemple : CUSTOMER_KEY2=\"val2, val2 val2\"

Cette syntaxe modélise étroitement les normes de définition des variables d'environnement bash.

--datalake-formats

Pris en charge dans AWS Glue 3.0 et versions ultérieures.

Spécifie la structure du lac de données à utiliser. AWS Glue ajoute les fichiers JAR requis pour les frameworks que vous spécifiez dans le `classpath`. Pour de plus amples informations, veuillez consulter [Utilisation de frameworks de lacs de données avec des tâches AWS Glue ETL](#).

Vous pouvez spécifier une ou plusieurs des valeurs suivantes, séparées par une virgule :

- hudi

- delta
- iceberg

Par exemple, transmettez l'argument suivant pour spécifier les trois infrastructures.

```
'--datalake-formats': 'hudi,delta,iceberg'
```

--disable-proxy-v2

Désactivez le proxy de AWS service pour autoriser les appels de service vers Amazon S3 et AWS Glue provenant de votre script via votre VPC. CloudWatch Pour plus d'informations, consultez [Configurer AWS les appels pour qu'ils passent par votre VPC](#). Pour désactiver le proxy de service, définissez la valeur de ce paramètre sur `true`.

--enable-auto-scaling

Lorsque cette valeur est paramétrée sur `true`, active la mise à l'échelle automatique ainsi que la facturation par employé.

--enable-continuous-cloudwatch-log

Permet la journalisation continue en temps réel des tâches AWS Glue. Vous pouvez afficher les journaux de tâches Apache Spark en temps réel dans CloudWatch.

--enable-continuous-log-filter

Spécifie un filtre standard (`true`) ou aucun filtre (`false`) lorsque vous créez ou modifiez une tâche activée pour la journalisation continue. Le choix du filtre standard élimine les pilotes/exécuteurs Apache Spark inutiles et les messages des journaux de pulsation Apache Hadoop YARN. Ne choisir aucun filtre vous donne tous les messages de journaux.

--enable-glue-datacatalog

Vous permet d'utiliser le catalogue de données AWS Glue comme métastore Apache Spark Hive. Pour activer cette fonctionnalité, définissez la valeur sur `true`.

--enable-job-insights

Permet une surveillance supplémentaire de l'analyse des erreurs grâce à AWS Glue Job Run Insights. Pour en savoir plus, consultez [the section called “Surveillance à l'aide AWS Glue d'informations sur l'exécution des tâches”](#). Par défaut, cette valeur est définie sur `true` et les informations sur l'exécution des tâches sont activées.

Cette option est disponible pour les versions 2.0 et 3.0 de AWS Glue.

--enable-lakeformation-fine-grained-access

Permet un contrôle d'accès précis pour les tâches AWS Glue. Pour de plus amples informations, veuillez consulter [the section called "Lake Formation pour le FGAC"](#).

--enable-metrics

Permet de collecter des métriques de profilage de tâche pour l'exécution de cette tâche. Ces statistiques sont disponibles sur les consoles AWS Glue et Amazon CloudWatch . La valeur de ce paramètre n'est pas pertinente. Pour activer cette fonctionnalité, vous pouvez attribuer à ce paramètre n'importe quelle valeur, mais la valeur `true` est recommandée pour des raisons de clarté. Pour désactiver cette fonctionnalité, supprimez ce paramètre de la configuration de votre tâche.

--enable-observability-metrics

Active un ensemble de mesures d'observabilité pour générer des informations sur ce qui se passe dans chaque tâche exécutée sur la page Job Runs Monitoring sous AWS la console Glue et la Amazon CloudWatch console. Pour activer cette fonctionnalité, définissez la valeur de ce paramètre sur « `true` ». Pour désactiver cette fonctionnalité, définissez-la sur `false` ou supprimez ce paramètre de la configuration de votre tâche.

--enable-rename-algorithm-v2

Définit la version de l'algorithme de renommage EMRFS sur la version 2. Lorsqu'une tâche Spark utilise le mode d'écrasement de partition dynamique, il est possible qu'une partition en double soit créée. Par exemple, vous pouvez vous retrouver avec une partition dupliquée telle que `s3://bucket/table/location/p1=1/p1=1`. Ici, P1 est la partition en cours de remplacement. Renommer l'algorithme en version 2 résout ce problème.

Cette option n'est disponible que sur la version 1.0 de AWS Glue.

--enable-s3-parquet-optimized-committer

Active le validateur EMRFS optimisé pour S3 pour l'écriture de données Parquet dans Amazon S3. Vous pouvez fournir la paire paramètre/valeur via la console AWS Glue lors de la création ou de la mise à jour d'une tâche Glue AWS . Définir la valeur sur **true** active le validateur. Par défaut, le drapeau est activé dans AWS Glue 3.0 et désactivé dans AWS Glue 2.0.

Pour de plus amples informations, veuillez consulter [Utilisation du validateur EMRFS optimisé pour S3](#).

--enable-spark-ui

Lorsque ce paramètre est défini sur `true`, active la fonctionnalité permettant d'utiliser l'interface utilisateur de Spark pour surveiller et déboguer les tâches AWS Glue ETL.

--executor-cores

Nombre de tâches Spark pouvant être exécutées en parallèle. Cette option est prise en charge sur AWS Glue 3.0+. La valeur ne doit pas dépasser le double du nombre de v CPUs sur le type de travailleur, qui est 8 activé G.1X, 16 activé G.2X, 32 activé G.4X et 64 activé G.8X. Vous devez faire preuve de prudence lors de la mise à jour de cette configuration, car cela peut avoir un impact sur les performances des tâches. En effet, l'augmentation du parallélisme des tâches entraîne une surcharge de la mémoire et des disques, ainsi qu'un ralentissement des systèmes source et cible (par exemple : cela entraînerait davantage de connexions simultanées sur Amazon RDS).

--extra-files

Les chemins Amazon S3 mènent à des fichiers supplémentaires, tels que des fichiers de configuration que AWS Glue copie dans le répertoire de travail de votre script sur le nœud du pilote avant de l'exécuter. Plusieurs valeurs doivent être des chemins entiers séparés par une virgule (,). Seuls les fichiers individuels sont pris en charge, et non un chemin de répertoire. Cette option n'est pas prise en charge pour les types de tâches shell Python.

--extra-jars

Les chemins Amazon S3 mènent à des fichiers supplémentaires que AWS Glue copie vers le pilote et les exécuteurs. AWS Glue ajoute également ces fichiers au chemin de classe Java avant d'exécuter votre script. Plusieurs valeurs doivent être des chemins entiers séparés par une virgule (,). Il n'est pas nécessaire que l'extension soit `.jar`.

--extra-py-files

Les chemins Amazon S3 vers des modules Python supplémentaires que AWS Glue ajoute au chemin Python sur le nœud pilote avant d'exécuter votre script. Plusieurs valeurs doivent être des chemins entiers séparés par une virgule (,). Seuls les fichiers individuels sont pris en charge, et non un chemin de répertoire.

--job-bookmark-option

Contrôle le comportement d'un signet de tâche. Les valeurs d'option suivantes peuvent être définies.

Valeur --job-bookmark-option	Description
<code>job-bookmark-enable</code>	Conserver une trace des données précédemment traitées. Lorsqu'une tâche s'exécute, traiter les nouvelles données depuis le dernier point de contrôle.
<code>job-bookmark-disable</code>	Toujours traiter l'intégralité de l'ensemble de données. Vous êtes responsable de la gestion de la sortie des exécutions de tâche précédentes.
<code>job-bookmark-pause</code>	Traitez les données progressives+ depuis la dernière exécution réussie ou les données de la plage identifiée par les sous-options suivantes, sans mettre à jour l'état du dernier marque-page. Vous êtes responsable de la gestion de la sortie des exécutions de tâche précédentes. Les deux sous-options sont les suivantes : • job-bookmark-from <from-value> est l'ID d'exécution qui représente toute l'entrée qui a été traitée jusqu'à la dernière exécution réussie jusqu'à l'ID d'exécution spécifié (compris). L'entrée correspondante est ignorée. • job-bookmark-to <to-value> est l'ID d'exécution qui représente toute l'entrée qui a été traitée jusqu'à la dernière exécution réussie jusqu'à l'ID d'exécution spécifié (compris). L'entrée correspondante, à l'exclusion de l'entrée identifiée par <from-value> , est traitée par la tâche. Toute entrée postérieure à cette entrée est également exclue pour traitement. L'état du marque-page de tâche n'est pas mis à jour lorsque cette option est spécifiée. Les sous-options sont facultatives. Cependant, lorsqu'elles sont utilisées, les deux sous-options doivent être fournies.

Par exemple, pour activer un marque-page de tâche, transmettez l'argument suivant :

```
'--job-bookmark-option': 'job-bookmark-enable'
```

--job-language

Langage de programmation des scripts. Cette valeur doit être `scala` ou `python`. Si le paramètre n'est pas présent, la valeur par défaut est `python`.

--python-modules-installer-option

Une chaîne de texte simple qui définit les options à transmettre à `pip3` lors de l'installation de modules avec [--additional-python-modules](#). Fournissez des options comme vous le feriez dans la ligne de commande, séparées par des espaces et préfixées par des tirets. Pour plus d'informations sur l'utilisation, consultez [the section called “Installation de modules Python supplémentaires avec pip dans AWS Glue 2.0 ou version ultérieure”](#).

Note

Cette option n'est pas prise en charge pour les tâches AWS Glue lorsque vous utilisez Python 3.9.

--scriptLocation

Emplacement Amazon Simple Storage Service (Amazon S3) dans lequel votre script ETL est situé (sous la forme `s3://path/to/my/script.py`). Ce paramètre remplace celui du script défini dans l'objet `JobCommand`.

--spark-event-logs-path

Spécifie un chemin d'accès Amazon S3. Lors de l'utilisation de la fonction de surveillance de l'interface utilisateur Spark, AWS Glue vide les journaux d'événements Spark vers ce chemin Amazon S3 toutes les 30 secondes dans un compartiment qui peut être utilisé comme répertoire temporaire pour stocker les événements de l'interface utilisateur Spark.

--TempDir

Spécifie un chemin Amazon S3 vers un compartiment qui peut être utilisé comme répertoire temporaire pour la tâche.

Par exemple, pour définir un répertoire temporaire, transmettez l'argument suivant :

```
'--TempDir': 's3-path-to-directory'
```

 Note

AWS Glue crée un compartiment temporaire pour les tâches s'il n'en existe pas déjà un dans une région. Ce compartiment peut permettre l'accès au public. Vous pouvez soit modifier le compartiment dans Amazon S3 pour définir le bloc d'accès public, soit supprimer le compartiment ultérieurement une fois toutes les tâches de cette région terminées.

--use-postgres-driver

Lorsque vous définissez cette valeur sur `true`, cela priorise le pilote JDBC Postgres dans le chemin de classe afin d'éviter tout conflit avec le pilote JDBC Amazon Redshift. Cette option n'est disponible que dans AWS la version 2.0 de Glue.

--user-jars-first

Lorsque vous définissez cette valeur sur `true`, cela priorise les fichiers JAR supplémentaires du client dans le chemin de classe. Cette option n'est disponible que dans AWS la version 2.0 ou ultérieure de Glue.

--conf

Contrôle les paramètres de configuration de Spark. Elle est destinée aux cas d'utilisation avancés.

--encryption-type

Paramètre hérité. Le comportement correspondant doit être configuré à l'aide des configurations de sécurité. Pour plus d'informations sur les configurations de sécurité, consultez [the section called “Chiffrement des données écrites par AWS Glue”](#).

AWS Glue utilise les arguments suivants en interne et vous ne devez jamais les utiliser :

- `--debug`— Interne à AWS Glue. Ne pas définir.
- `--mode`— Interne à AWS Glue. Ne pas définir.
- `--JOB_NAME`— Interne à AWS Glue. Ne pas définir.
- `--endpoint`— Interne à AWS Glue. Ne pas définir.

AWS Glue permet de démarrer un environnement à l'aide du site module Python `sitecustomize` pour effectuer des personnalisations spécifiques au site. L'amorçage de vos propres fonctions d'initialisation est recommandé uniquement pour les cas d'utilisation avancés et est pris en charge dans toute la mesure du possible sur Glue 4.0. AWS

Le préfixe de la variable d'environnement, `GLUE_CUSTOMER`, est réservé à l'usage du client.

AWS Glue Spark et PySpark jobs

AWS Glue soutenez Spark et PySpark jobs. Une tâche Spark est exécutée dans un environnement Apache Spark géré par AWS Glue. Elle traite les données par lots. Une tâche ETL en streaming est similaire à une tâche Spark, sauf qu'elle exécute ETL sur des flux de données. Elle utilise le cadre Apache Spark Structured Streaming. Certaines fonctionnalités de tâche Spark ne sont pas disponibles pour les tâches ETL en streaming.

Les sections suivantes fournissent des informations sur AWS Glue Spark et les PySpark jobs.

Rubriques

- [Configuration des propriétés des tâches pour les tâches Spark dans AWS Glue](#)
- [Modification de scripts Spark dans AWS Glue console](#)
- [Tâches \(hérité\)](#)
- [Suivi des données traitées à l'aide de signets de tâche](#)
- [Stockage des données Spark Shuffle](#)
- [Surveillance AWS Glue Offres d'emploi Spark](#)
- [Résolution des problèmes liés à l'IA générative pour Apache Spark in AWS Glue](#)

Configuration des propriétés des tâches pour les tâches Spark dans AWS Glue

Lorsque vous définissez votre tâche sur la AWS Glue console, vous fournissez des valeurs pour les propriétés permettant de contrôler l'environnement AWS Glue d'exécution.

Définition des propriétés des tâches Spark

La liste suivante contient les propriétés d'une tâche Spark. Pour les propriétés d'une tâche shell Python, consultez [Définition des propriétés pour les tâches shell Python](#). Pour les propriétés d'une

tâche ETL en streaming, consultez [the section called “Définition des propriétés de tâche pour une tâche ETL en streaming”](#).

Les propriétés sont répertoriées dans l'ordre dans lequel elles apparaissent dans l'assistant d'ajout d'une tâche sur AWS Glue la console.

Nom

Fournit une chaîne UTF-8 d'une longueur maximale de 255 caractères

Description

Fournissez une description facultative de 2 048 caractères maximum.

Rôle IAM

Spécifiez le rôle IAM qui permet de définir les autorisations d'accès aux ressources utilisées pour exécuter la tâche et accéder aux magasins de données. Pour plus d'informations sur les autorisations relatives à l'exécution de tâches dans AWS Glue, consultez [Gestion des identités et des accès pour AWS Glue](#).

Type

Type de tâche ETL. Ce paramètre est défini automatiquement en fonction du type de sources de données que vous sélectionnez.

- Spark exécute un script ETL Apache Spark avec la commande `jobglueetl`.
- Spark Streaming exécute un script ETL de streaming Apache Spark avec la commande `jobgluestreaming`. Pour de plus amples informations, veuillez consulter [the section called “Tâches ETL en streaming”](#).
- Python shell exécute un script Python avec la commande `jobpythonshell`. Pour de plus amples informations, veuillez consulter [Configuration des propriétés des tâches pour les tâches du shell Python dans AWS Glue](#).

Version AWS Glue

AWS Glue version détermine les versions d'Apache Spark et Python disponibles pour la tâche, comme indiqué dans le tableau suivant.

AWS Glue version	Versions Spark et Python prises en charge
5.0	• Spark 3.5.4 • Python 3.11

AWS Glue version	Versions Spark et Python prises en charge
4.0	• Spark 3.3.0 • Python 3.10
3.0	• Spark 3.1.1 • Python 3.7

Langue

Le code inclus dans le script ETL permet de définir la logique de votre tâche. Le script peut être codé dans Python ou dans Scala. Vous pouvez choisir si le script exécuté par le job est généré par vous AWS Glue ou fourni par vous. Vous fournissez le nom et l'emplacement du script dans Amazon Simple Storage Service (Amazon S3). Vérifiez qu'il n'existe pas de fichier portant le même nom que le répertoire de script dans le chemin d'accès. Pour en savoir plus sur l'écriture de scripts, consultez [AWS Glue guide de programmation](#).

Type d'employé

Les types d'employé suivantes sont disponibles :

Les ressources disponibles pour les AWS Glue travailleurs sont mesurées en DPUs. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire.

- **G.1X** – Lorsque vous choisissez ce type, vous devez également fournir une valeur pour Number of workers (Nombre d'employés). Chaque utilisateur est mappé sur 1 DPU (4 VCPUs, 16 Go de mémoire) avec un disque de 94 Go. Nous recommandons ce type de travailleur pour les charges de travail telles que les transformations de données, les jointures et les requêtes, afin de proposer un moyen évolutif et rentable d'exécuter la plupart des tâches.
- **G.2X** – Lorsque vous choisissez ce type, vous devez également fournir une valeur pour Number of workers (Nombre d'employés). Chaque utilisateur est mappé sur 2 DPU (8 VCPUs, 32 Go de mémoire) avec un disque de 138 Go. Nous recommandons ce type de travailleur pour les charges de travail telles que les transformations de données, les jointures et les requêtes, afin de proposer un moyen évolutif et rentable d'exécuter la plupart des tâches.
- **G.4X** – Lorsque vous choisissez ce type, vous devez également fournir une valeur pour Number of workers (Nombre d'employés). Chaque utilisateur mappe sur 4 processeurs (16 VCPUs, 64 Go de mémoire) avec un disque de 256 Go (environ 235 Go libres). Nous

recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes.

- **G.8X** – Lorsque vous choisissez ce type, vous devez également fournir une valeur pour Number of workers (Nombre d'employés). Chaque utilisateur mappe 8 DPU (32 VCPUs, 128 Go de mémoire) sur un disque de 512 Go (environ 487 Go libres). Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes.
- **G.025X** – Lorsque vous choisissez ce type, vous devez également fournir une valeur pour Number of workers (Nombre d'employés). Chaque utilisateur est mappé sur 0,25 DPU (2 VCPUs, 4 Go de mémoire) avec un disque de 84 Go (environ 34 Go libres). Nous recommandons ce type d'employé pour les travaux de streaming à faible volume. Ce type de travailleur n'est disponible que pour les tâches de streaming en AWS Glue version 3.0 ou ultérieure.

Un taux horaire vous est facturé en fonction du nombre de tâches DPUs utilisées pour exécuter vos tâches ETL. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

Pour les tâches de AWS Glue version 1.0 ou antérieures, lorsque vous configurez une tâche à l'aide de la console et que vous spécifiez un type de travailleur Standard, la capacité maximale est définie et le nombre de travailleurs devient la valeur de Capacité maximale - 1. Si vous utilisez le AWS Command Line Interface (AWS CLI) ou le AWS SDK, vous pouvez spécifier le paramètre Capacité maximale, ou vous pouvez spécifier à la fois le type de travailleur et le nombre de travailleurs.

Pour les tâches de AWS Glue la version 2.0 ou ultérieure, vous ne pouvez pas spécifier de capacité maximale. Au lieu de cela, vous devez spécifier le Worker type (Type d'employé) et le Number of workers (Nombre d'employés).

G.4X et les types de **G.8X** travailleurs sont disponibles uniquement pour les tâches Spark ETL AWS Glue version 3.0 ou ultérieure dans les AWS régions suivantes : USA Est (Ohio), USA Est (Virginie du Nord), USA Ouest (Californie du Nord), USA Ouest (Oregon), Asie-Pacifique (Mumbai), Asie-Pacifique (Séoul), Asie-Pacifique (Sydney), Asie-Pacifique (Tokyo), Canada (Centre), Europe (Francfort), Europe (Irlande), Europe (Londres), Europe (Espagne), Europe (Stockholm) et Amérique du Sud (São Paulo).

Nombre de travailleurs demandé

Pour la plupart des types d'employés, vous devez spécifier le nombre de travailleurs qui sont alloués lors de l'exécution de la tâche.

Marque-page de tâche

Spécifiez la manière dont AWS Glue les informations d'état sont traitées lors de l'exécution de la tâche. Ce signet peut se souvenir des données traitées précédemment, mettre à jour les informations sur l'état ou ignorer les informations sur l'état. Pour de plus amples informations, veuillez consulter [the section called “Suivi des données traitées à l'aide de signets de tâche”](#).

Mise en file d'attente pour l'exécution des tâches

Spécifie si les exécutions de tâches sont mises en file d'attente pour être exécutées ultérieurement lorsqu'elles ne peuvent pas être exécutées immédiatement en raison de quotas de service.

Lorsque cette case est cochée, la mise en file d'attente des tâches est activée pour les exécutions de tâches. S'ils ne sont pas renseignés, les exécutions de tâches ne seront pas prises en compte pour la mise en file d'attente.

Si ce paramètre ne correspond pas à la valeur définie lors de l'exécution du travail, la valeur du champ d'exécution du travail sera utilisée.

Exécution flexible

Lorsque vous configurez une tâche à l'aide de AWS Studio ou de l'API, vous pouvez spécifier une classe d'exécution de tâche standard ou flexible. Vos tâches peuvent avoir différents degrés de priorité et de sensibilité au temps. La classe d'exécution standard est idéale pour les charges de travail urgentes qui nécessitent un démarrage rapide des tâches et des ressources dédiées.

La classe d'exécution flexible convient aux tâches non urgentes telles que les tâches de pré-production, les tests et les chargements de données uniques. Les exécutions flexibles sont prises en charge pour les tâches utilisant AWS Glue la version 3.0 ou ultérieure et/ou les G.1X types de G.2X travailleurs.

Les exécutions de tâches flexibles sont facturées en fonction du nombre de travailleurs en cours d'exécution à un moment donné dans le temps. Le nombre de travailleurs peut être ajouté ou supprimé pour une exécution flexible en cours d'exécution. Au lieu de facturer comme un simple calcul de `Max Capacity * Execution Time`, chaque travailleur contribuera pour le temps qu'il a effectué pendant l'exécution du travail. La facture est la somme de `(Number of DPUs per worker * time each worker ran)`.

Pour plus d'informations, consultez le panneau d'aide de AWS Studio, ou [Tâches](#) et [Exécutions de tâches](#).

Nombre de nouvelles tentatives

Spécifiez le nombre de fois, de 0 à 10, qui AWS Glue devrait redémarrer automatiquement la tâche en cas d'échec. Les tâches qui atteignent la limite de délai d'expiration ne sont pas redémarrées.

Délai d'expiration de la tâche

Définit le délai d'exécution maximal en minutes. Le maximum est de 7 jours ou 10 080 minutes. Dans le cas contraire, les tâches généreront une exception.

Lorsque la valeur est laissée vide, le délai d'expiration est défini par défaut à 2880 minutes.

Toutes les AWS Glue tâches existantes dont le délai d'expiration est supérieur à 7 jours seront définies par défaut sur 7 jours. Par exemple, si vous avez spécifié un délai d'expiration de 20 jours pour un traitement par lots, celui-ci sera arrêté le 7ème jour.

Bonnes pratiques en matière de délais de travail

Les tâches sont facturées en fonction du temps d'exécution. Pour éviter des frais imprévus, configurez des valeurs de délai d'expiration adaptées à la durée d'exécution prévue de votre tâche.

Propriétés avancées

Nom du fichier du script

Un nom de script unique pour votre tâche. Ne peut pas être nommé Poste sans titre.

Chemin du script

L'emplacement du script sur Amazon S3. Le chemin doit être de la forme `s3://bucket/prefix/path/`. Il doit se terminer par une barre oblique (/) et ne pas inclure de fichiers.

Métriques de tâche

Activez ou désactivez la création de CloudWatch métriques Amazon lors de l'exécution de cette tâche. Pour afficher les données de profilage, vous devez activer cette option. Pour en savoir plus sur l'activation et la visualisation de métriques, consultez [Surveillance et débogage des tâches](#).

Indicateurs d'observabilité des emplois

Activez la création de CloudWatch mesures d'observabilité supplémentaires lors de l'exécution de cette tâche. Pour de plus amples informations, veuillez consulter [the section called “Surveillance avec AWS Glue Métriques d'observabilité”](#).

Journalisation continue

Activez la journalisation continue sur Amazon CloudWatch. Si cette option n'est pas activée, les journaux ne sont disponibles qu'une fois la tâche terminée. Pour en savoir plus, consultez [the section called “Journalisation pour les AWS Glue emplois”](#).

Interface utilisateur Spark

Permettez l'utilisation de l'interface utilisateur Spark pour la surveillance de cette tâche. Pour de plus amples informations, veuillez consulter [Activation de l'interface utilisateur Web d'Apache Spark pour AWS Glue jobs](#).

Chemin des journaux de l'interface utilisateur Spark

Le chemin pour écrire les journaux lorsque l'interface utilisateur de Spark est activée.

Configuration de journalisation et de surveillance de l'interface utilisateur Spark

Choisissez l'une des options suivantes :

- Standard : écrivez des journaux en utilisant l'ID AWS Glue d'exécution du job comme nom de fichier. Activez la surveillance de l'interface utilisateur Spark dans la AWS Glue console.
- Legacy : écrivez des journaux en utilisant « spark-application- {timestamp} » comme nom de fichier. N'activez pas la surveillance de l'interface utilisateur Spark.
- Standard et ancien : rédigez des journaux à la fois dans les emplacements standard et traditionnels. Activez la surveillance de l'interface utilisateur Spark dans la AWS Glue console.

Simultanéité maximum

Définit le nombre maximal d'exécutions simultanées autorisées pour cette tâche. La valeur par défaut est 1. Une erreur est renvoyée lorsque ce seuil est atteint. La valeur maximale que vous pouvez spécifier est contrôlée par une limite de service. Par exemple, si une tâche est toujours en cours d'exécution lorsqu'une nouvelle instance est lancée, vous pouvez souhaiter le renvoi d'une erreur pour empêcher deux instances de la même tâche de s'exécuter simultanément.

Chemin temporaire

Indiquez l'emplacement d'un répertoire de travail dans Amazon S3 où les résultats intermédiaires temporaires sont écrits lors de l' AWS Glue exécution du script. Vérifiez qu'il n'existe pas de fichier portant le même nom que le répertoire temporaire dans le chemin d'accès. Ce répertoire est utilisé lors des opérations de AWS Glue lecture et d'écriture sur Amazon Redshift et lors de certaines AWS Glue transformations.

Note

AWS Glue crée un compartiment temporaire pour les tâches s'il n'en existe pas déjà un dans une région. Ce compartiment peut permettre l'accès au public. Vous pouvez soit modifier le compartiment dans Amazon S3 pour définir le bloc d'accès public, soit supprimer le compartiment ultérieurement une fois toutes les tâches de cette région terminées.

Seuil de notification de délai (minutes)

Définit le seuil (en minutes) avant l'envoi d'une notification de dépassement de délai. Vous pouvez définir ce seuil pour envoyer des notifications lorsqu'une exécution de tâche RUNNING, STARTING ou STOPPING prend plus de temps que le nombre de minutes prévu.

Configuration de la sécurité

Choisissez une configuration de sécurité dans la liste. Une configuration de sécurité spécifie la manière dont les données de la cible Amazon S3 sont chiffrées : pas de chiffrement, chiffrement côté serveur avec des clés gérées par AWS KMS(SSE-KMS) ou clés de chiffrement gérées par Amazon S3 (SSE-S3).

Chiffrement côté serveur

Si vous sélectionnez cette option, lorsque la tâche ETL écrit sur Amazon S3, les données sont chiffrées au repos à l'aide du chiffrement SSE-S3. Votre cible de données Amazon S3 et toutes les données qui sont écrites dans un répertoire temporaire Amazon S3 sont chiffrées. Cette option est transmise en tant que paramètre de tâche. Pour en savoir plus, consultez la section [Protecting Data Using Server-Side Encryption with Amazon S3-Managed Encryption Keys \(SSE-S3\)](#) (Protection des données à l'aide du chiffrement côté serveur avec des clés de chiffrement (SSE-S3) gérées par Amazon S3) dans le guide de l'utilisateur Amazon Simple Storage Service.

 Important

Cette option est ignorée si une configuration de sécurité est spécifiée.

Utiliser le catalogue de données Glue en tant que metastore Hive

Sélectionnez cette option pour utiliser le catalogue de AWS Glue données comme métastore Hive. Le rôle IAM utilisé pour la tâche doit disposer de l'autorisation `glue:CreateDatabase`. Une base de données appelée « default » est créée dans le catalogue de données si elle n'existe pas.

Connexions

Choisissez une configuration VPC pour accéder aux sources de données Amazon S3 situées dans votre cloud privé virtuel (VPC). Vous pouvez créer et gérer une connexion réseau dans AWS Glue. Pour de plus amples informations, veuillez consulter [Connexion aux données](#).

Bibliothèques

Chemin de bibliothèque Python, JARs chemin dépendant et chemin des fichiers référencés

Spécifiez ces options si votre script les requiert. Vous pouvez définir des chemins Amazon S3 séparés par des virgules pour ces options lorsque vous définissez la tâche. Vous pouvez remplacer ces chemins lorsque vous exécutez la tâche. Pour de plus amples informations, veuillez consulter [Fournir vos propres scripts personnalisés](#).

Paramètres des tâches

Ensemble de paires clé-valeur transmises sous forme de paramètres nommés au script. Il s'agit de valeurs par défaut qui sont utilisées lors de l'exécution du script, mais vous pouvez les remplacer dans les déclencheurs ou lorsque vous exécutez la tâche. Vous devez préfixer le nom de la clé avec `--` ; par exemple : `--myKey`. Vous transmettez les paramètres de la tâche sous forme de carte lorsque vous utilisez le AWS Command Line Interface.

Pour accéder à des exemples, veuillez consulter les paramètres Python dans [Transmission et accès aux paramètres Python dans AWS Glue](#).

Balises

Identifiez votre tâche avec une clé d'identification et avec une valeur d'identification facultative. Lorsque les clés d'identification sont créées, elles sont en lecture seule. Utilisez des

identifications sur certaines ressources pour mieux les organiser et les identifier. Pour de plus amples informations, veuillez consulter [AWS tags dans AWS Glue](#).

Restrictions pour les tâches qui accèdent aux tables gérées par Lake Formation

Tenez compte des remarques et restrictions suivantes lorsque vous créez des tâches qui lisent ou écrivent dans des tables gérées par AWS Lake Formation :

- Les fonctions suivantes ne sont pas prises en charge dans les tâches qui accèdent à des tables comportant des filtres au niveau des cellules :
 - [Marque-pages de tâche](#) et [exécution limitée](#)
 - [Prédicats pushdown](#)
 - [Prédicats de partition de catalogue côté serveur](#)
 - [enableUpdateCatalog](#)

Modification de scripts Spark dans AWS Glue console

Un script contient le code qui extrait les données des sources, les transforme et les charge dans des cibles. AWS Glue exécute un script lorsqu'il démarre une tâche.

AWS Glue Les scripts ETL peuvent être codés en Python ou en Scala. Les scripts Python utilisent un langage qui est une extension du dialecte PySpark Python pour les tâches d'extraction, de transformation et de chargement (ETL). Le script contient des structures étendues pour gérer les transformations ETL. Lorsque vous générez automatiquement la logique de code source pour votre tâche, un script est créé. Vous pouvez modifier ce script ou fournir votre propre script personnalisé pour effectuer votre travail ETL.

Pour plus d'informations sur la définition et la modification de scripts dans AWS Glue, voir [AWS Glue guide de programmation](#).

Bibliothèques ou fichiers supplémentaires

Si votre script nécessite des bibliothèques ou des fichiers supplémentaires, vous pouvez les spécifier comme suit :

Chemin de la bibliothèque Python

Chemins Amazon Simple Storage Service (Amazon S3) séparés par des virgules vers les bibliothèques Python requises par le script.

 Note

Seules les bibliothèques Python pures peuvent être utilisées. Les bibliothèques reposant sur des extensions C, par exemple la bibliothèque d'analyse des données Python pandas, ne sont pas encore prises en charge.

Chemin des fichiers .jar dépendants

Chemins Amazon S3 séparés par des virgules vers les fichiers JAR requis par le script.

 Note

À l'heure actuelle, seules les bibliothèques pures Java ou Scala (2.11) peuvent être utilisées.

Chemin de fichiers référencés

Chemins Amazon S3 séparés par des virgules vers les fichiers supplémentaires (par exemple, des fichiers de configuration) requis par le script.

Tâches (hérité)

Un script contient le code qui permet d'effectuer un travail ETL (extraction, transformation et chargement). Vous pouvez fournir votre propre script, ou AWS Glue peut générer un script avec vos conseils. Pour plus d'informations sur la création de vos propres scripts, consultez [Fournir vos propres scripts personnalisés](#).

Vous pouvez modifier un script dans AWS Glue console. Lorsque vous modifiez un script, vous pouvez ajouter des sources, des cibles et des transformations.

Pour modifier un script

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>. Ensuite, choisissez l'onglet Jobs (Tâches).
2. Choisissez une tâche dans la liste, puis choisissez Action, Edit script (Modifier le script) pour ouvrir l'éditeur de script.

Vous pouvez également accéder à l'éditeur de script à partir de la page des détails de la tâche. Sélectionnez l'onglet Script, puis Edit script (Modifier le script).

Éditeur de script

Le AWS Glue L'éditeur de script vous permet d'insérer, de modifier et de supprimer des sources, des cibles et des transformations dans votre script. L'éditeur de script affiche à la fois le script et un diagramme pour vous aider à visualiser le flux de données.

Pour créer un diagramme pour le script, choisissez Générer un diagramme. AWS Glue utilise des lignes d'annotation dans le script commençant par `##` pour afficher le diagramme. Pour représenter correctement votre script dans le diagramme, vous devez conserver la synchronisation entre les paramètres dans les annotations et les paramètres dans le code Apache Spark.

L'éditeur de script vous permet d'ajouter des modèles de code à chaque fois que votre curseur est positionné dans le script. Dans la partie supérieure de l'éditeur, choisissez l'une des options suivantes :

- Pour ajouter une table source au script, choisissez Source (Source).
- Pour ajouter une table cible au script, choisissez Target (Cible).
- Pour ajouter un emplacement cible au script, choisissez Target location (Emplacement cible).
- Pour ajouter une transformation au script, choisissez Transform (Transformation). Pour plus d'informations sur les fonctions appelées dans votre script, consultez [Programmez les scripts ETL AWS Glue dans PySpark](#).
- Pour ajouter une transformation Spigot au script, choisissez Spigot.

Dans le code inséré, modifiez l'élément `parameters` dans les annotations et dans le code Apache Spark. Par exemple, si vous ajoutez une transformation Spigot, vérifiez que l'élément `path` est remplacé dans la ligne d'annotation `@args` et dans la ligne de code `output`.

L'onglet Logs (Journaux) présente les journaux associés à votre travail pendant son exécution. Les 1 000 lignes les plus récentes sont affichées.

L'onglet Schema (Schéma) présente le schéma des sources et des cibles sélectionnées, lorsqu'elles sont disponibles dans Data Catalog.

Suivi des données traitées à l'aide de signets de tâche

AWS Glue suit les données qui ont déjà été traitées lors d'une exécution précédente d'une tâche ETL en conservant les informations d'état issues de l'exécution de la tâche. Ces informations d'état permanentes sont appelées marque-pages de tâches. Aide aux favoris d'offres d'emploi AWS Glue conserver les informations d'état et empêcher le retraitement des anciennes données. Avec les marque-pages de tâche, vous pouvez traiter de nouvelles données lors de la réexécution sur un intervalle planifié. Un marque-page de tâche se compose des états des différents éléments de tâches, tels que les sources, les transformations et les cibles. Par exemple, votre tâche ETL peut lire de nouvelles partitions dans un fichier Amazon S3. AWS Glue suit les partitions traitées avec succès par la tâche afin d'éviter le double traitement et la duplication de données dans le magasin de données cible de la tâche.

Les marque-pages de tâche sont implémentés pour les sources de données JDBC, la transformation Relationalize et certaines sources Amazon Simple Storage Service (Amazon S3). Le tableau suivant répertorie les formats de source Amazon S3 qui AWS Glue supports pour les signets d'offres d'emploi.

AWS Glue version	Formats source Amazon S3
Version 0.9	JSON, CSV, Apache Avro, XML
Version 1.0 et ultérieure	JSON, CSV, Apache Avro, XML, Parquet, ORC

Pour plus d'informations sur AWS Glue versions, voir [Définition des propriétés des tâches Spark](#).

La fonction de signets de tâches comporte des fonctionnalités supplémentaires lorsqu'elle est accessible via AWS Glue des scripts. Lorsque vous parcourez le script que vous avez généré, vous pouvez voir des contextes de transformation liés à cette fonctionnalité. Pour de plus amples informations, veuillez consulter [the section called "Utilisation des marque-pages de tâche"](#).

Rubriques

- [Utilisation des signets d'offres d'emploi dans AWS Glue](#)
- [Détails opérationnels de la fonctionnalité de signets de tâche](#)

Utilisation des signets d'offres d'emploi dans AWS Glue

L'option de marque-page de tâche est transmise sous forme de paramètre au démarrage de la tâche. Le tableau suivant décrit les options permettant de définir des signets de tâches sur AWS Glue console.

Marque-page de tâche	Description
Enable	La tâche met à jour l'état après une exécution pour suivre les données traitées précédemment. Si votre tâche a une source avec prise en charge du marque-page de tâche, elle suit les données traitées et, lorsqu'une tâche est exécutée, elle traite les nouvelles données depuis le dernier point de contrôle.
Désactiver	Les marque-pages de tâche ne sont pas utilisés et la tâche traite toujours la totalité du jeu de données. Vous êtes responsable de la gestion de la sortie des exécutions de tâche précédentes. Il s'agit de l'option par défaut.
Pause	Traitez les données progressives depuis la dernière exécution réussie ou les données de la plage identifiée par les sous-options suivantes, sans mettre à jour l'état du dernier marque-page. Vous êtes responsable de la gestion de la sortie des exécutions de tâche précédentes. Les deux sous-options sont les suivantes : • <code>job-bookmark-from<from-value></code> est l'ID d'exécution qui représente toutes les entrées traitées jusqu'à la dernière exécution réussie précédente, y compris l'ID d'exécution spécifié. L'entrée correspondante est ignorée. • <code>job-bookmark-to<to-value></code> est l'ID d'exécution qui représente toutes les entrées traitées jusqu'à la dernière exécution réussie précédente, y compris l'ID d'exécution spécifié. L'entrée correspondante, à l'exclusion de l'entrée identifiée par <code><from-value></code>, est traitée par la tâche. Toute entrée postérieure à cette entrée est également exclue pour traitement.

Marque-page de tâche	Description
	L'état du marque-page de tâche n'est pas mis à jour lorsque ce jeu d'options est spécifié. Les sous-options sont facultatives, mais lorsqu'elles sont utilisées, les deux sous-options doivent être fournies.

Pour plus d'informations sur les paramètres transmis à une tâche sur la ligne de commande, et plus particulièrement pour les marque-pages de tâche, consultez [Utilisation des paramètres des tâches dans les tâches AWS Glue](#).

Pour les sources d'entrée Amazon S3, AWS Glue les signets de tâches vérifient l'heure de dernière modification des objets pour vérifier quels objets doivent être retraités. Si les données de la source d'entrée ont été modifiées depuis votre dernière exécution de tâche, les fichiers sont traités de nouveau lorsque vous exécutez la tâche à nouveau.

Pour les sources JDBC, les règles suivantes s'appliquent :

- Pour chaque table, AWS Glue utilise une ou plusieurs colonnes comme clés de signet pour déterminer les données nouvelles et traitées. Les touches de marque-page se combinent pour former une seule clé composée.
- AWS Glue utilise par défaut la clé primaire comme clé de signet, à condition qu'elle augmente ou diminue de manière séquentielle (sans interruption).
- Vous pouvez spécifier les colonnes à utiliser comme clés de signet dans votre AWS Glue script. Pour plus d'informations sur l'utilisation des signets Job dans les AWS Glue scripts, consultez [the section called "Utilisation des marque-pages de tâche"](#).
- AWS Glue ne prend pas en charge l'utilisation de colonnes dont les noms distinguent majuscules et minuscules comme clés de signet de tâche.

Vous pouvez modifier les favoris de vos offres d'emploi pour votre AWS Glue Ajoutez des tâches ETL à n'importe quelle tâche exécutée précédemment. Les opérations de remplacement automatique de données sont mieux prises en charge : quand un marque-page de tâche déjà exécutée est restauré sur une exécution de tâche précédente, les exécutions de tâche ultérieures ne retraitent que les données à partir de l'exécution de tâche marquée par le marque-page.

Si vous avez l'intention de retraiter toutes les données à l'aide de la même tâche, réinitialisez le marque-page de tâche. Pour réinitialiser l'état du signet de la tâche, utilisez AWS Glue console, le fonctionnement de l'[ResetJobBookmark action \(Python : `reset\_job\_bookmark`\)](#) API ou le AWS CLI. Par exemple, entrez la commande suivante à l'aide de l' AWS CLI :

```
aws glue reset-job-bookmark --job-name my-job-name
```

Lorsque vous revenez en arrière ou que vous réinitialisez un signet, AWS Glue ne nettoie pas les fichiers cibles car il peut y avoir plusieurs cibles et les cibles ne sont pas suivies à l'aide de signets de tâches. Seuls les fichiers source sont suivis à l'aide de marque-pages de tâche. Vous pouvez créer différentes cibles de sortie lors de la restauration et du retraitement des fichiers source pour éviter les doublons de données dans votre sortie.

AWS Glue assure le suivi des signets de tâches par tâche. Si vous supprimez une tâche, le marque-page de tâche est supprimé.

Dans certains cas, vous avez peut-être activé AWS Glue des signets de tâches, mais votre tâche ETL retraite des données qui ont déjà été traitées lors d'une exécution précédente. Pour plus d'informations sur la résolution des causes courantes de cette erreur, consultez [Résolution des erreurs Erreurs Spark](#).

Détails opérationnels de la fonctionnalité de signets de tâche

Cette section décrit plus de détails opérationnels sur l'utilisation des marque-pages de tâche.

Les marque-pages de tâche stockent les états d'une tâche. Chaque instance de l'état est identifiée par un nom et un numéro de version. Lorsqu'un script appelle `job.init`, il extrait son état et obtient toujours la dernière version. Au sein d'un état, il y a plusieurs éléments d'état, qui sont spécifiques à chaque source, la transformation et l'instance de récepteur dans le script. Ces éléments d'état sont identifiés par un contexte de transformation qui est attaché à l'élément correspondant (source, transformation ou récepteur) dans le script. Les éléments d'état sont enregistrés de manière atomique lorsque `job.commit` est appelé depuis le script utilisateur. Le script obtient le nom de la tâche et l'option de contrôle pour les marque-pages de tâches depuis les arguments.

Les éléments d'état dans le marque-page de tâche sont les données de la source, de la transformation ou des données spécifiques au récepteur. Par exemple, supposons que vous souhaitiez lire des données progressives à partir d'un emplacement Amazon S3 qui est constamment

écrit par une tâche ou un processus en amont. Dans ce cas, le script doit déterminer ce qui a été traité jusqu'à présent. L'implémentation du marque-page de tâche pour la source Amazon S3 enregistre des informations pour que, lors de la prochaine exécution de la tâche, elle puisse filtrer uniquement les nouveaux objets à l'aide des informations enregistrées et recalculer l'état de la prochaine exécution de la tâche. Un horodatage est utilisé pour filtrer les nouveaux fichiers.

Outre les éléments d'état, les marque-pages de tâche ont un nombre d'exécutions, un nombre de tentatives et un numéro de version. Le nombre d'exécutions suit l'exécution de la tâche et le nombre de tentatives enregistre les tentatives d'une exécution de tâche. Le nombre d'exécutions d'une tâche est un nombre croissant de façon monotone incrémenté pour chaque exécution réussie. Le nombre de tentatives suit les tentatives de chaque exécution, et il est incrémenté uniquement lorsqu'il y a une exécution après une tentative en échec. Le numéro de version augmente de façon monotone et effectue le suivi des mises à jour d'un marque-page de tâche.

Dans la base de données de AWS Glue service, les états des signets pour toutes les transformations sont stockés ensemble sous forme de paires clé-valeur :

```
{
  "job_name" : ...,
  "run_id": ...,
  "run_number": ..,
  "attempt_number": ...
  "states": {
    "transformation_ctx1" : {
      bookmark_state1
    },
    "transformation_ctx2" : {
      bookmark_state2
    }
  }
}
```

Bonnes pratiques

Les bonnes pratiques suivantes sont recommandées pour utiliser des signets de tâche.

- Ne modifiez pas la propriété de la source de données lorsque le marque-page est activé. Par exemple, une source de données 0 pointe vers un chemin d'entrée A Amazon S3, et la tâche est en cours de lecture à partir d'une source exécutée pendant plusieurs tours avec le marque-page activé. Si vous remplacez le chemin d'entrée de `datasource0` par le chemin B d'Amazon S3 sans le modifier `transformation_ctx`, la AWS Glue tâche utilisera l'ancien état des favoris enregistré.

Cela se traduira par des fichiers manquants ou ignorés dans le chemin d'entrée B, comme cela AWS Glue supposerait que ces fichiers ont été traités lors d'exécutions précédentes.

- Utiliser un tableau de catalogue avec des marque-pages pour une meilleure gestion des partitions. Les marque-pages fonctionnent à la fois pour les sources de données du catalogue de données ou à partir d'options. Cependant, il est difficile de supprimer/ajouter de nouvelles partitions avec l'approche « à partir d'options ». L'utilisation d'un tableau de catalogue avec des crawlers peut fournir une meilleure automatisation pour suivre les [partitions](#) nouvellement ajoutées et vous offre la flexibilité nécessaire pour sélectionner des partitions particulières avec un [prédicat pushdown](#).
- Utiliser le [listeur de fichiers Amazon S3 AWS Glue](#) pour les jeux de données volumineux. Un marque-page répertorie tous les fichiers sous chaque partition d'entrée et effectue le filtrage. Par conséquent, s'il y a trop de fichiers sous une seule partition, le marque-page peut être exécuté dans le pilote OOM. Utilisez le listeur de fichiers AWS Glue Amazon S3 pour éviter de répertorier tous les fichiers en mémoire en une seule fois.

Stockage des données Spark Shuffle

La réorganisation est une étape importante d'une tâche Spark chaque fois que les données sont réarrangées entre des partitions. Elle est nécessaire parce que de larges transformations telles que `join`, `groupByKey`, `reduceByKey` et `repartition` ont besoin d'informations provenant d'autres partitions pour terminer le traitement. Spark rassemble les données requises de chaque partition et les combine dans une nouvelle partition. Lors d'une réorganisation, les données sont écrites sur le disque et transférées via le réseau. Par conséquent, l'opération de réorganisation est liée à la capacité du disque local. Spark émet une erreur `No space left on device` ou `MetadataFetchFailedException` lorsqu'il n'y a pas assez d'espace disque sur le programme d'exécution et qu'il n'y a pas de récupération.


Note

AWS Glue Le plugin Spark shuffle avec Amazon S3 n'est pris en charge que pour les tâches AWS Glue ETL.

Solution

Avec AWS Glue, vous pouvez désormais utiliser Amazon S3 pour stocker les données Spark Shuffle. Amazon S3 est un service de stockage d'objets qui offre une évolutivité, une disponibilité des données, une sécurité et des performances de pointe. Cette solution désagrège le calcul et

le stockage pour vos tâches Spark, et offre une élasticité totale et un stockage économique de la réorganisation, ce qui vous permet d'exécuter vos applications les plus complexes de manière fiable.



Nous introduisons un nouveau plug-in Cloud Shuffle Storage pour Apache Spark afin d'utiliser Amazon S3. Vous pouvez activer Amazon S3 shuffling pour exécuter votre AWS Glue des tâches

fiables et sans défaillance si l'on sait qu'elles sont limitées par la capacité du disque local pour les opérations de brassage de grande envergure. Dans certains cas, une réorganisation vers Amazon S3 est légèrement plus lente que vers un disque local (ou EBS) si vous avez un grand nombre de petites partitions ou de fichiers réorganisés écrits dans Amazon S3.

Conditions préalables à l'utilisation du plug-in de stockage de réorganisation du cloud.

Pour utiliser le plug-in de stockage Cloud Shuffle avec des tâches AWS Glue ETL, vous avez besoin des éléments suivants :

- Un compartiment Amazon S3 situé dans la même région que celle de votre exécution de tâche, pour stocker la réorganisation intermédiaire et les données déversées. Le préfixe Amazon S3 du stockage de réorganisation peut être spécifié avec `--conf spark.shuffle.glue.s3ShuffleBucket=s3://shuffle-bucket/prefix/`, comme dans l'exemple suivant :

```
--conf spark.shuffle.glue.s3ShuffleBucket=s3://glue-shuffle-123456789-us-east-1/glue-shuffle-data/
```

- Définissez les stratégies de cycle de vie du stockage Amazon S3 sur le préfixe (tel que `glue-shuffle-data`), car le gestionnaire de réorganisation ne nettoie pas les fichiers une fois la tâche terminée. La réorganisation intermédiaire et les données déversées doivent être supprimées une fois la tâche terminée. Les utilisateurs peuvent définir des stratégies de cycle de vie court pour le préfixe. Les instructions de configuration d'une stratégie de cycle de vie Amazon S3 sont disponibles dans la section [Configuration du cycle de vie d'un compartiment](#) dans le Guide de l'utilisateur Amazon Simple Storage Service.

Utilisation AWS Glue Gestionnaire de shuffle Spark depuis la console AWS

Pour configurer le AWS Glue Gestionnaire de shuffle Spark utilisant le AWS Glue console ou AWS Glue Studio lors de la configuration d'une tâche : choisissez le paramètre de tâche `-- write-shuffle-files-to -s3` pour activer le shuffling Amazon S3 pour la tâche.

Job parameters

Key	Value - optional
--write-shuffle-files- X	X
Remove	
Add new parameter	

You can add 49 more parameters.

Utilisation AWS Glue Plug-in Spark Shuffle

Les paramètres de tâche suivants activent et ajustent le AWS Glue gestionnaire de shuffle. Ces paramètres étant des indicateurs, les valeurs fournies ne sont pas prises en compte.

- `--write-shuffle-files-to-s3`— Le drapeau principal, qui active le AWS Glue Spark Shuffle Manager pour utiliser les compartiments Amazon S3 pour écrire et lire des données de shuffle. Lorsque l'indicateur n'est pas spécifié, le gestionnaire de réorganisation n'est pas utilisé.
- `--write-shuffle-spills-to-s3`— (Supporté uniquement sur AWS Glue version 2.0). Indicateur facultatif qui vous permet de décharger des fichiers de déversement dans des compartiments Amazon S3, pour une résilience supplémentaire de votre tâche Spark. Ceci n'est requis que pour les charges de travail volumineuses qui déversent beaucoup de données sur le disque. Lorsque l'indicateur n'est pas spécifié, aucun fichier de déversement intermédiaire n'est écrit.
- `--conf spark.shuffle.glue.s3ShuffleBucket=s3://<shuffle-bucket>`
– autre indicateur facultatif spécifiant le compartiment Amazon S3 dans lequel vous écrivez les fichiers de réorganisation. Par défaut, `--TempDir /shuffle-data`. AWS Glue La version 3.0+ prend en charge l'écriture de fichiers shuffle dans plusieurs compartiments en spécifiant des compartiments avec un séparateur par virgule, comme dans. `--conf spark.shuffle.glue.s3ShuffleBucket=s3://shuffle-bucket-1/prefix,s3://shuffle-bucket-2/prefix`/ L'utilisation de plusieurs compartiments améliore les performances.

Vous devez fournir des paramètres de configuration de sécurité pour activer le chiffrement au repos des données de réorganisation. Pour plus d'informations sur les configurations de sécurité, consultez [the section called “Configuration du chiffrement”](#). AWS Glue prend en charge toutes les autres configurations liées au shuffle fournies par Spark.

Binaires logiciels pour le plug-in Cloud Shuffle Storage

Vous pouvez également télécharger les fichiers binaires du plug-in Cloud Shuffle Storage pour Apache Spark sous la licence Apache 2.0 et l'exécuter dans n'importe quel environnement Spark. Le nouveau plugin est compatible avec out-of-the Amazon S3 et peut également être facilement configuré pour utiliser d'autres formes de stockage dans le cloud, telles que [Google Cloud Storage et Microsoft Azure Blob Storage](#). Pour plus d'informations, consultez [Cloud Shuffle Storage Plugin for Apache Spark](#) (Plug-in Cloud Shuffle Storage pour Apache Spark).

Remarques et limitations

Vous trouverez ci-dessous des remarques ou des restrictions concernant le AWS Glue gestionnaire de shuffle :

- AWS Glue le gestionnaire de shuffle ne supprime pas automatiquement les fichiers de données de shuffle (temporaires) stockés dans votre compartiment Amazon S3 une fois la tâche terminée. Pour garantir la protection des données, suivez les instructions fournies dans [Conditions préalables à l'utilisation du plug-in de stockage de réorganisation du cloud](#), avant d'activer le plug-in Cloud Shuffle Storage.
- Vous pouvez utiliser cette fonction si vos données sont biaisées.

Cloud Shuffle Storage Plugin pour Apache Spark

Cloud Shuffle Storage Plugin est un plug-in Apache Spark compatible avec l'[API ShuffleDataIO](#) qui permet de stocker des données aléatoires sur des systèmes de stockage cloud (tels qu'Amazon S3). Il vous aide à compléter ou à remplacer la capacité de stockage sur disque local pour les opérations de lecture aléatoire de grande envergure, généralement déclenchées par des transformations telles que `join`, `reduceByKey`, `groupByKey` et `repartition` dans vos applications Spark, réduisant ainsi les défaillances courantes ou les problèmes de rapport prix/performances de vos tâches et pipelines d'analyse de données sans serveur.

AWS Glue

AWS Glue les versions 3.0 et 4.0 sont livrées avec le plugin préinstallé et prêt à activer le shuffling vers Amazon S3 sans aucune étape supplémentaire. Pour plus d'informations, consultez [AWS Glue Plug-in Spark Shuffle avec Amazon S3](#) pour activer cette fonctionnalité pour vos applications Spark.

Autres environnements Spark

Le plug-in exige que les configurations Spark suivantes soient définies sur d'autres environnements Spark :

- `--conf spark.shuffle.sort.io.plugin.class=com.amazonaws.spark.shuffle.io.cloud.Chopper`
indique à Spark d'utiliser ce plug-in pour Shuffle IO.
- `--conf spark.shuffle.storage.path=s3://bucket-name/shuffle-file-dir:`
chemin de stockage de vos fichiers de lecture aléatoire.

Note

Le plug-in remplace une classe principale de Spark. Par conséquent, le fichier jar du plug-in doit être chargé avant les fichiers jar de Spark. Vous pouvez le faire `userClassPathFirst` en utilisant des environnements YARN sur site si le plugin est utilisé à l'extérieur AWS Glue.

Création d'une offre groupée du plug-in pour vos applications Spark

Vous pouvez intégrer le plug-in à vos applications et distributions Spark (versions 3.1 et supérieures) en ajoutant la dépendance du plug-in dans votre fichier `pom.xml` Maven, tout en développant vos applications Spark en local. Pour plus d'informations sur les versions du plug-in et de Spark, consultez [Versions du plug-in](#).

```
<repositories>
  ...
  <repository>
    <id>aws-glue-etl-artifacts</id>
    <url>https://aws-glue-etl-artifacts.s3.amazonaws.com/release/ </url>
  </repository>
</repositories>
...
<dependency>
  <groupId>com.amazonaws</groupId>
  <artifactId>chopper-plugin</artifactId>
  <version>3.1-amzn-LATEST</version>
</dependency>
```

Vous pouvez également télécharger les fichiers binaires directement à partir des artefacts AWS Glue Maven et les inclure dans votre application Spark comme suit.

```
#!/bin/bash
sudo wget -v https://aws-glue-etl-artifacts.s3.amazonaws.com/release/com/amazonaws/
chopper-plugin/3.1-amzn-LATEST/chopper-plugin-3.1-amzn-LATEST.jar -P /usr/lib/spark/
jars/
```

Exemple d'utilisation de spark-submit

```
spark-submit --deploy-mode cluster \
--conf spark.shuffle.storage.s3.path=s3://<ShuffleBucket>/<shuffle-dir> \
--conf spark.driver.extraClassPath=<Path to plugin jar> \
--conf spark.executor.extraClassPath=<Path to plugin jar> \
--class <your test class name> s3://<ShuffleBucket>/<Your application jar> \
```

Configurations facultatives

Il s'agit de valeurs de configuration facultatives qui contrôlent le comportement de lecture aléatoire d'Amazon S3.

- `spark.shuffle.storage.s3.enableServerSideEncryption` : active/désactive S3 SSE pour les fichiers de lecture aléatoire et de débordement. La valeur par défaut est `true`.
- `spark.shuffle.storage.s3.serverSideEncryption.algorithm` : algorithme SSE à utiliser. La valeur par défaut est `AES256`.
- `spark.shuffle.storage.s3.serverSideEncryption.kms.key` : ARN de la clé KMS lorsque SSE `aws:kms` est activé.

Outre ces configurations, vous devrez peut-être définir des configurations telles que `spark.hadoop.fs.s3.enableServerSideEncryption` et d'autres configurations spécifiques à l'environnement pour garantir que le chiffrement approprié est appliqué à votre cas d'utilisation.

Versions du plug-in

Ce plugin est pris en charge pour les versions de Spark associées à chaque AWS Glue version. Le tableau suivant indique la AWS Glue version, la version de Spark et la version du plugin associée avec l'emplacement Amazon S3 du binaire logiciel du plugin.

AWS Glue version	Version de Spark	Version du plug-in	Emplacement Amazon S3
3.0	3.1	3.1-amzn-LATEST	s3 ://aws-glue-etl-artifacts/release/com/amazonaws/chopper-plugin/3.1-amzn-0/chopper-Plugin-3.1-amzn-Latest.jar
4.0	3.3	3.3-amzn-LATEST	s3 ://aws-glue-etl-artifacts/release/com/amazonaws/chopper-plugin/3.3-amzn-0/chopper-Plugin-3.3-amzn-latest.jar

Licence

Le fichier binaire logiciel de ce plug-in est concédé sous licence dans le cadre de la licence Apache-2.0.

Surveillance AWS Glue Offres d'emploi Spark

Rubriques

- [Spark Metrics est disponible dans AWS Glue Studio](#)
- [Surveillance des tâches à l'aide de l'interface utilisateur web Apache Spark](#)
- [Surveillance à l'aide AWS Glue d'informations sur l'exécution des tâches](#)
- [Surveillance avec Amazon CloudWatch](#)
- [Surveillance et débogage des tâches](#)

Spark Metrics est disponible dans AWS Glue Studio

L'onglet Metrics (Métriques) montre les métriques collectées lorsqu'une tâche s'exécute et que le profilage est activé. Les graphiques suivants sont affichés dans les tâches Spark :

- Déplacement de données ETL
- Profil de la mémoire : pilote et programmes d'exécution

Choisissez View Additional Metrics (Afficher des métriques supplémentaires) pour afficher les graphiques suivants :

- Déplacement de données ETL
- Profil de la mémoire : pilote et programmes d'exécution
- Remaniement de données sur les programmes d'exécution
- Chargement de l'UC : pilote et programmes d'exécution
- Exécution de tâche : programmes d'exécution actifs, étapes achevées et nombre de programmes d'exécution maximum nécessaires

Les données de ces graphiques sont transférées vers CloudWatch des métriques si la tâche est configurée pour collecter des métriques. Pour plus d'informations sur l'activation de métriques et l'interprétation de graphiques, veuillez consulter [Surveillance et débogage des tâches](#).

Exemple Graphique du déplacement de données ETL


Le graphique du Déplacement de données ETL montre les métriques suivantes :

- Le nombre d'octets lus à partir d'Amazon S3 par tous les programmes d'exécution —[glue.ALL.s3.filesystem.read_bytes](#)
- Le nombre d'octets écrits à partir d'Amazon S3 par tous les programmes d'exécution – [glue.ALL.s3.filesystem.write_bytes](#)

Jobs > e2e-straggler

Detailed job metrics


ETL Data Movement



Exemple Graphique du profil de mémoire

Le graphique du profil de la mémoire montre les métriques suivantes :

- La portion de mémoire utilisée par la pile de la JVM pour ce pilote (mise à l'échelle : 0-1) par le pilote, un programme d'exécution identifié par `executorId` ou tous les exécuteurs –
 - [glue.driver.jvm.heap.usage](#)
 - [glue.executorId.jvm.heap.usage](#)
 - [glue.ALL.jvm.heap.usage](#)




Exemple Graphique de remaniement de données sur les programmes d'exécution

Le graphique de remaniement de données sur les programmes d'exécution montre les métriques suivantes :

- Le nombre d'octets lus par tous les programmes d'exécution pour remanier des données sur ceux-ci - [glue.driver.aggregate.shuffleLocalBytesRead](#)
- Le nombre d'octets écrits par tous les programmes d'exécution pour remanier des données sur ceux-ci - [glue.driver.aggregate.shuffleBytesWritten](#)

Data Shuffle Across Executors




Exemple Graphique de chargement de l'UC

Le graphique de chargement de l'UC montre les métriques suivantes :

- La fraction de la charge du système CPU utilisée (mise à l'échelle : 0-1) par le pilote, un programme d'exécution identifié par executorId ou tous les exécuteurs –
 - [glue.driver.system.cpuSystemLoad](#)
 - [glue.executorId.system.cpuSystemLoad](#)
 - [glue.ALL.system.cpuSystemLoad](#)


CPU Load: Driver and Executors



Exemple Graphique d'exécution de tâche

Le graphique d'exécution de tâche montre les métriques suivantes :

- Le nombre de programmes d'exécution actifs en cours d'exécution - [glue.driver.ExecutorAllocationManager.executors.numberAllExecutors](#)
- Le nombre d'étapes terminées - [glue.aggregate.numCompletedStages](#)
- Le nombre maximum de programmes d'exécution nécessaires - [glue.driver.ExecutorAllocationManager.executors.numberMaxNeededExecutors](#)



Surveillance des tâches à l'aide de l'interface utilisateur web Apache Spark

Vous pouvez utiliser l'interface utilisateur Web d'Apache Spark pour surveiller et déboguer AWS Glue Tâches ETL exécutées sur AWS Glue système de tâches, ainsi que les applications Spark exécutées sur AWS Glue points de terminaison du développement. L'interface utilisateur Spark vous permet de vérifier les éléments suivants pour chaque tâche :

- La chronologie des événements de chaque phase Spark
- Un graphe orienté acyclique (DAG) de la tâche
- Les plans physiques et logiques des requêtes SparkSQL
- Les variables environnementales Spark sous-jacentes pour chaque tâche

Pour plus d'informations sur l'utilisation de l'interface utilisateur web Spark, consultez l'[Interface utilisateur web](#) dans la documentation Spark. Pour obtenir des conseils sur la façon d'interpréter les résultats de l'interface utilisateur Spark afin d'améliorer les performances de votre tâche, consultez les [meilleures pratiques en matière de réglage des performances AWS Glue pour les tâches Apache Spark](#) dans le guide AWS prescriptif.

Vous pouvez voir l'interface utilisateur de Spark dans la AWS Glue console. Ceci est disponible lorsqu'une AWS Glue tâche s'exécute sur des versions AWS Glue 3.0 ou ultérieures avec des journaux générés au format standard (plutôt qu'ancien), qui est le format par défaut pour les nouvelles tâches. Si vos fichiers journaux sont supérieurs à 0,5 Go, vous pouvez activer la prise en

charge des journaux progressifs pour les exécutions de tâches sur les versions AWS Glue 4.0 ou ultérieures afin de simplifier l'archivage, l'analyse et le dépannage des journaux.

Vous pouvez activer l'interface utilisateur Spark à l'aide du AWS Glue console ou le AWS Command Line Interface (AWS CLI). Lorsque vous activez l'interface utilisateur Spark, AWS Glue Tâches ETL et applications Spark sur AWS Glue les points de terminaison de développement peuvent sauvegarder les journaux d'événements Spark à un emplacement que vous spécifiez dans Amazon Simple Storage Service (Amazon S3). Vous pouvez utiliser les journaux d'événements sauvegardés dans Amazon S3 avec l'interface utilisateur Spark à la fois en temps réel, lorsque la tâche est en cours de fonctionnement, et une fois celle-ci terminée. Tant que les journaux restent dans Amazon S3, l'interface utilisateur Spark de la AWS Glue console peut les consulter.

Autorisations

Pour utiliser l'interface utilisateur Spark dans la AWS Glue console, vous pouvez utiliser UseGlueStudio ou ajouter tous les services individuels APIs. Tous APIs sont nécessaires pour utiliser complètement l'interface utilisateur Spark, mais les utilisateurs peuvent accéder aux fonctionnalités de SparkUI en ajoutant son service APIs dans leur autorisation IAM pour un accès détaillé.

RequestLogParsingest le plus critique car il effectue l'analyse des journaux. Le reste APIs est destiné à la lecture des données analysées respectives. Permet par exemple d'GetStagesaccéder aux données relatives à toutes les étapes d'une tâche Spark.

La liste des services Spark UI APIs UseGlueStudio mappés se trouve ci-dessous dans l'exemple de politique. La politique ci-dessous permet d'utiliser uniquement les fonctionnalités de l'interface utilisateur de Spark. Pour ajouter d'autres autorisations, comme Amazon S3 et IAM, consultez la section [Création de politiques IAM personnalisées](#) pour. AWS Glue Studio

La liste des services Spark UI APIs mappés se UseGlueStudio trouve ci-dessous dans l'exemple de politique. Lorsque vous utilisez une API de service Spark UI, utilisez l'espace de noms suivant : glue:<ServiceAPI>

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "AllowGlueStudioSparkUI",
      "Effect": "Allow",
```



```

    "Action": [
        "glue:RequestLogParsing",
        "glue:GetLogParsingStatus",
        "glue:GetEnvironment",
        "glue:GetJobs",
        "glue:GetJob",
        "glue:GetStage",
        "glue:GetStages",
        "glue:GetStageFiles",
        "glue:BatchGetStageFiles",
        "glue:GetStageAttempt",
        "glue:GetStageAttemptTaskList",
        "glue:GetStageAttemptTaskSummary",
        "glue:GetExecutors",
        "glue:GetExecutorsThreads",
        "glue:GetStorage",
        "glue:GetStorageUnit",
        "glue:GetQueries",
        "glue:GetQuery"
    ],
    "Resource": [
        "*"
    ]
}
]
}

```

Limites

- L'interface utilisateur Spark de la AWS Glue console n'est pas disponible pour les exécutions de tâches effectuées avant le 20 novembre 2023 car elles sont dans l'ancien format de journal.
- L'interface utilisateur Spark de la AWS Glue console prend en charge les journaux AWS Glue évolutifs pour la version 4.0, tels que ceux générés par défaut dans les tâches de streaming. La somme maximale de tous les fichiers d'événements enregistrés générés est de 2 Go. Pour les AWS Glue tâches ne prenant pas en charge les journaux cumulés, la taille maximale du fichier journal des événements pris en charge par SparkUI est de 0,5 Go.
- L'interface utilisateur Spark sans serveur n'est pas disponible pour les journaux d'événements Spark stockés dans un compartiment Amazon S3 auquel seul votre VPC peut accéder.

Exemple : interface utilisateur web Apache Spark

Cet exemple vous montre comment utiliser l'interface utilisateur Spark pour comprendre vos performances pour la tâche. Les captures d'écran montrent l'interface utilisateur web Spark telle que fournie par un serveur d'historique Spark autogéré. L'interface utilisateur Spark de la AWS Glue console fournit des vues similaires. Pour plus d'informations sur l'utilisation de l'interface utilisateur web Spark, consultez l'[Interface utilisateur web](#) dans la documentation Spark.

Voici un exemple d'application Spark qui lit à partir de deux sources de données, effectue une transformation de jointure et écrit le tout dans Amazon S3 au format Parquet.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from pyspark.sql.functions import count, when, expr, col, sum, isnull
from pyspark.sql.functions import countDistinct
from awsglue.dynamicframe import DynamicFrame

args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session


job = Job(glueContext)
job.init(args['JOB_NAME'])

df_persons = spark.read.json("s3://awsglue-datasets/examples/us-legislators/all/
persons.json")
df_memberships = spark.read.json("s3://awsglue-datasets/examples/us-legislators/all/
memberships.json")

df_joined = df_persons.join(df_memberships, df_persons.id == df_memberships.person_id,
'fullouter')
df_joined.write.parquet("s3://aws-glue-demo-sparkui/output/")

job.commit()
```

La visualisation DAG suivante montre les différentes phases de cette tâche Spark.



La chronologie d'événements suivante pour une tâche montre le début, l'exécution et la résiliation de différents exécuteurs Spark.

APACHE

Spark

2.2.1

tape-sparksql-jr_80b2f86d42bfb62... application UI

Jobs

Stages

Storage

Environment


Executors

SQL

Details for Job 2

Status: SUCCEEDED
Completed Stages: 3

▼ Event Timeline
☐ Enable zooming



- ▶ DAG Visualization
- ▶ Completed Stages (3)

L'écran suivant montre les détails des plans de requête SparkSQL :

- Plan logique analysé
- Plan logique d'analyse
- Plan logique optimisé
- Plan physique d'exécution

APACHE

SPARK™

2.2.1

tape-sparksql-jr_80b2f86d42bfb62... application UI

Jobs

Stages

Storage


Environment

Executors

SQL

Details for Query 0

Submitted Time: 2019/09/11 02:30:37
Duration: 34 s
Succeeded Jobs: 2



Details

```
== Parsed Logical Plan ==
Join FullOuter, (id#14 = person_id#50)
:-
Relation[birth_date#8,contact_details#9,death_date#10,family_name#11,gender#12,given_name#13,id#14,identifiers#15
,image#16,images#17,links#18,name#19,other_names#20,sort_name#21] json
+-
Relation[area_id#45,end_date#46,legislative_period_id#47,on_behalf_of_id#48,organization_id#49,person_id#50,role#
51,start_date#52] json

== Analyzed Logical Plan ==
birth_date: string, contact_details: array<struct<type:string,value:string>>, death_date: string, family_name:
string, gender: string, given_name: string, id: string, identifiers:
array<struct<identifier:string,scheme:string>>, image: string, images: array<struct<url:string>>, links:
array<struct<url:string>>, name: string, other_names:
array<struct<lang:string,name:string,note:string>>, sort_name: string, area_id: string, end_date: string,
legislative_period_id: string, on_behalf_of_id: string, organization_id: string, person_id: string, role: string,
start_date: string
Join FullOuter, (id#14 = person_id#50)
```

Rubriques

- [Activation de l'interface utilisateur Web d'Apache Spark pour AWS Glue jobs](#)
- [Lancement du serveur d'historique Spark](#)

Activation de l'interface utilisateur Web d'Apache Spark pour AWS Glue jobs

Vous pouvez utiliser l'interface utilisateur Web d'Apache Spark pour surveiller et déboguer AWS Glue Tâches ETL exécutées sur le AWS Glue système de travail. Vous pouvez configurer l'interface utilisateur de Spark à l'aide du AWS Glue console ou le AWS Command Line Interface (AWS CLI).

Toutes les 30 secondes, AWS Glue sauvegarde les journaux d'événements Spark sur le chemin Amazon S3 que vous spécifiez.

Rubriques

- [Configuration de l'interface utilisateur Spark \(console\)](#)
- [Configuration de l'interface utilisateur Spark \(AWS CLI\)](#)
- [Configuration de l'interface utilisateur Spark pour des sessions utilisant des blocs-notes](#)
- [Activer les journaux roulants](#)

Configuration de l'interface utilisateur Spark (console)

Suivez ces étapes pour configurer l'interface utilisateur Spark à l'aide de la AWS Management Console. Lors de la création d'une AWS Glue tâche, l'interface utilisateur Spark est activée par défaut.

Pour activer l'interface utilisateur Spark lorsque vous créez ou modifiez une tâche

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le volet de navigation, sélectionnez Tâches.
3. Choisissez Ajouter une tâche ou sélectionnez-en une existante.
4. Dans Détails de la tâche, ouvrez les Propriétés avancées.
5. Sous l'onglet Interface utilisateur Spark, choisissez Écrire des journaux de l'interface utilisateur Spark sur Amazon S3.
6. Spécifiez un chemin Amazon S3 pour stocker les journaux d'événements Spark pour la tâche. Notez que si vous utilisez une configuration de sécurité dans la tâche, le chiffrement s'applique

également au fichier journal de l'interface utilisateur Spark. Pour de plus amples informations, veuillez consulter [Chiffrement de données écrites par AWS Glue](#).

7. Dans la Configuration de journalisation et de surveillance de l'interface utilisateur Spark :

- Sélectionnez Standard si vous générez des journaux à afficher dans la AWS Glue console.
- Sélectionnez Hérité si vous générez des journaux à afficher sur un serveur d'historique Spark.
- Vous pouvez également choisir de générer les deux.

Configuration de l'interface utilisateur Spark (AWS CLI)

Pour générer des journaux à consulter avec l'interface utilisateur de Spark, dans la AWS Glue console, utilisez le AWS CLI pour transmettre les paramètres de tâche suivants à AWS Glue emplois. Pour de plus amples informations, veuillez consulter [the section called "Paramètres des tâches"](#).

```
'--enable-spark-ui': 'true',  
'--spark-event-logs-path': 's3://s3-event-log-path'
```

Pour distribuer les journaux dans leurs anciens emplacements, définissez le paramètre `--enable-spark-ui-legacy-path` sur `"true"`. Si vous ne souhaitez pas générer de journaux dans les deux formats, supprimez le paramètre `--enable-spark-ui`.

Configuration de l'interface utilisateur Spark pour des sessions utilisant des blocs-notes

Warning

AWS Glue les sessions interactives ne prennent actuellement pas en charge l'interface utilisateur Spark dans la console. Configurez un serveur d'historique Spark.

Si vous utilisez des AWS Glue blocs-notes, configurez la configuration de SparkUI avant de démarrer la session. Pour ce faire, utilisez le magic cellulaire de `%%configure` :

```
%%configure { "--enable-spark-ui": "true", "--spark-event-logs-path": "s3://path" }
```

Activer les journaux roulants

L'activation de SparkUI et des fichiers d'événements du journal continu pour les AWS Glue tâches présentent plusieurs avantages :

- Fichiers journaux d'événements continus : lorsque les fichiers journaux d'événements sont activés, des fichiers journaux distincts sont AWS Glue générés pour chaque étape de l'exécution de la tâche, ce qui facilite l'identification et le dépannage des problèmes spécifiques à une étape ou à une transformation en particulier.
- Meilleure gestion des journaux : le roulement des fichiers d'événements permet de gérer les fichiers journaux de manière plus efficace. Au lieu d'avoir un seul fichier journal potentiellement volumineux, les journaux sont divisés en fichiers plus petits et plus faciles à gérer en fonction des étapes d'exécution des tâches. Cela peut simplifier l'archivage, l'analyse et le dépannage des journaux.
- Tolérance aux pannes améliorée — Si une AWS Glue tâche échoue ou est interrompue, les fichiers d'événements du journal continu peuvent fournir des informations précieuses sur la dernière étape réussie, ce qui permet de reprendre plus facilement la tâche à partir de ce point plutôt que de repartir de zéro.
- Optimisation des coûts — En activant les fichiers journaux d'événements continus, vous pouvez économiser sur les coûts de stockage associés aux fichiers journaux. Au lieu de stocker un seul fichier journal potentiellement volumineux, vous stockez des fichiers journaux plus petits et plus faciles à gérer, ce qui peut être plus rentable, en particulier pour les tâches complexes ou de longue durée.

Dans un nouvel environnement, les utilisateurs peuvent activer explicitement les journaux progressifs via :

```
'-conf': 'spark.eventLog.rolling.enabled=true'
```

or

```
'-conf': 'spark.eventLog.rolling.enabled=true -conf  
spark.eventLog.rolling.maxFileSize=128m'
```

Lorsque les journaux déroulants sont activés, `spark.eventLog.rolling.maxFileSize` spécifie la taille maximale du fichier journal des événements avant qu'il ne soit transféré. La valeur par défaut de ce paramètre facultatif, s'il n'est pas spécifié, est de 128 Mo. Le minimum est de 10 Mo.

La somme maximale de tous les fichiers d'événements enregistrés générés est de 2 Go. Pour les AWS Glue tâches sans support de journalisation continue, la taille maximale du fichier journal des événements pris en charge par SparkUI est de 0,5 Go.

Vous pouvez désactiver les journaux propagés pour une tâche de streaming en fournissant une configuration supplémentaire. Notez que la maintenance de fichiers journaux très volumineux peut coûter cher.

Pour désactiver les journaux propagés, fournissez la configuration suivante :

```
'--spark-ui-event-logs-path': 'true',  
'--conf': 'spark.eventLog.rolling.enabled=false'
```

Lancement du serveur d'historique Spark

Vous pouvez utiliser un serveur d'historique Spark pour visualiser les journaux Spark sur votre propre infrastructure. Vous pouvez voir les mêmes visualisations dans la AWS Glue console pour les exécutions de AWS Glue tâches sur les versions AWS Glue 4.0 ou ultérieures avec des journaux générés au format standard (plutôt qu'ancien). Pour de plus amples informations, veuillez consulter [the section called “Surveillance à l'aide de l'interface utilisateur Spark”](#).

Vous pouvez lancer le serveur d'historique Spark à l'aide d'un AWS CloudFormation modèle hébergeant le serveur sur une EC2 instance, ou le lancer localement à l'aide de Docker.

Rubriques

- [Lancement du serveur d'historique Spark et affichage de l'interface utilisateur de Spark à l'aide de AWS CloudFormation](#)
- [Lancement du serveur d'historique Spark et affichage de l'interface utilisateur Spark à l'aide de Docker](#)

Lancement du serveur d'historique Spark et affichage de l'interface utilisateur de Spark à l'aide de AWS CloudFormation

Vous pouvez utiliser un AWS CloudFormation modèle pour démarrer le serveur d'historique Apache Spark et afficher l'interface utilisateur Web de Spark. Ces modèles sont des exemples que vous devez modifier pour répondre à vos besoins.

Pour démarrer le serveur d'historique Spark et afficher l'interface utilisateur de Spark à l'aide de AWS CloudFormation

1. Choisissez l'un des boutons Launch Stack (Lancer la pile) du tableau suivant. Cela lance la pile sur la AWS CloudFormation console.

Région	Lancer
USA Est (Ohio)	Launch Stack 
USA Est (Virginie du Nord)	Launch Stack 
USA Ouest (Californie du Nord)	Launch Stack 
USA Ouest (Oregon)	Launch Stack 
Afrique (Le Cap)	Launch Stack 
Asie-Pacifique (Hong Kong)	Launch Stack 
Asia Pacific (Mumbai)	Launch Stack 
Asie-Pacifique (Osaka)	Launch Stack 
Asia Pacific (Seoul)	Launch Stack 
Asie-Pacifique (Singapour)	Launch Stack 
Asie-Pacifique (Sydney)	Launch Stack 
Asie-Pacifique (Tokyo)	Launch Stack 
Canada (Centre)	Launch Stack 
Europe (Francfort)	Launch Stack 

Région	Lancer
Europe (Irlande)	
Europe (Londres)	
Europe (Milan)	
Europe (Paris)	
Europe (Stockholm)	
Moyen-Orient (Bahreïn)	
Amérique du Sud (São Paulo)	

2. Sur la page Specify template (Spécifier un modèle), choisissez Next (Suivant).
3. Sur la page Specify stack details (Spécifier les détails de la pile), entrez le nom de la pile (Stack name). Saisissez des informations supplémentaires sous Paramètres.
 - a. Configuration de l'interface utilisateur Spark

Saisissez les informations suivantes :

- IP address range (Plage d'adresses IP) – Plage d'adresses IP pouvant être utilisée pour afficher l'interface utilisateur Spark. Pour limiter l'accès à partir d'une plage d'adresses IP spécifique, vous devez utiliser une valeur personnalisée.
- History server port (Historique du serveur) – Port de l'interface utilisateur Spark. Vous pouvez utiliser la valeur par défaut.
- Répertoire des journaux d'événements : choisissez l'emplacement où les journaux d'événements Spark sont stockés dans AWS Glue points de terminaison d'emploi ou de développement. Vous devez utiliser `s3a://` pour le schéma de chemin des journaux d'événements.
- Spark package location (Emplacement du package Spark) – Vous pouvez utiliser la valeur par défaut.

- Keystore path (Chemin du KeyStore) – Chemin d'accès du magasin de clés SSL/TLS pour HTTPS. Si vous souhaitez utiliser un fichier de magasin de clés personnalisé, vous pouvez spécifier le chemin S3 `s3://path_to_your_keystore_file` ici. Si vous laissez ce paramètre vide, un magasin de clés auto-signé basé sur un certificat est généré et utilisé.
- Mot de passe KeyStore — Saisissez le mot de passe du magasin de clés SSL/TLS pour HTTPS.

b. EC2 configuration de l'instance

Saisissez les informations suivantes :

- Type d'instance : type d' EC2 instance Amazon hébergeant le serveur d'historique Spark. Étant donné que ce modèle lance une EC2 instance Amazon sur votre compte, les EC2 frais Amazon seront facturés séparément sur votre compte.
- Latest AMI ID (Dernier ID AMI) – ID AMI d'Amazon Linux 2 pour l'instance du serveur d'historique Spark. Vous pouvez utiliser la valeur par défaut.
- VPC ID (ID VPC) – ID du cloud privé virtuel (VPC) pour l'instance du serveur d'historique Spark. Vous pouvez utiliser n'importe lequel des éléments VPCs disponibles dans votre compte. Il n'est pas recommandé d'utiliser un VPC [par défaut avec une ACL réseau par défaut](#). Pour plus d'informations, veuillez consulter les rubriques [VPC par défaut et sous-réseaux par défaut](#) et [Créer un VPC](#) dans le Guide de l'utilisateur Amazon VPC.
- Subnet ID (ID de sous-réseau) – ID de l'instance du serveur d'historique Spark. Vous pouvez utiliser n'importe quel sous-réseau de votre VPC. Vous devez être en mesure d'atteindre le réseau depuis votre client vers le sous-réseau. Pour y accéder via Internet, vous devez utiliser un sous-réseau public dont la table de routage comporte la passerelle Internet.

c. Choisissez Suivant.

4. Sur la page Configurer les options de la pile, pour utiliser les informations d'identification utilisateur actuelles afin de déterminer CloudFormation comment créer, modifier ou supprimer des ressources dans la pile, choisissez Next. Vous pouvez également spécifier un rôle dans la section Autorisations à utiliser au lieu des autorisations utilisateur actuelles, puis choisissez Suivant.
5. Sur la page Review (Révision), vérifiez le modèle.

Sélectionnez Je reconnais que cela AWS CloudFormation pourrait créer des ressources IAM, puis choisissez Create stack.

6. Attendez que la pile soit créée.
7. Ouvrez l'onglet Sorties.
 - a. Copiez l'URL de SparkUiPublicUrls si vous utilisez un sous-réseau public.
 - b. Copiez l'URL de SparkUiPrivateUrls si vous utilisez un sous-réseau privé.
8. Ouvrez un navigateur web et collez-y l'URL. Cela vous permet d'accéder au serveur à l'aide de HTTPS sur le port spécifié. Votre navigateur peut ne pas reconnaître le certificat du serveur ; dans ce cas, vous devez outrepasser sa protection et continuer tout de même.

Lancement du serveur d'historique Spark et affichage de l'interface utilisateur Spark à l'aide de Docker

Si vous préférez un accès local (ne pas avoir d' EC2 instance pour le serveur d'historique Apache Spark), vous pouvez également utiliser Docker pour démarrer le serveur d'historique Apache Spark et afficher l'interface utilisateur de Spark localement. Ce fichier Dockerfile est un exemple que vous devez modifier pour répondre à vos besoins.

Prérequis

Pour plus d'informations sur l'installation de Docker sur votre ordinateur portable, consultez la [communauté Docker Engine](#).

Pour démarrer le serveur d'historique Spark et afficher l'interface utilisateur Spark localement à l'aide de Docker

1. Téléchargez des fichiers depuis GitHub.

Téléchargez le Dockerfile et depuis pom.xml [AWS Glue exemples de code](#).

2. Déterminez si vous souhaitez utiliser vos informations d'identification utilisateur ou vos informations d'identification utilisateur fédéré pour accéder à AWS.
 - Pour utiliser les informations d'identification utilisateur actuelles pour accéder AWS, obtenez les valeurs à utiliser pour `AWS_ACCESS_KEY_ID` et `AWS_SECRET_ACCESS_KEY` dans la commande `docker run`. Pour de plus amples informations, veuillez consulter [Gestion des clés d'accès pour les utilisateurs IAM](#) dans le Guide de l'utilisateur IAM.
 - Pour utiliser les utilisateurs fédérés SAML 2.0 pour l'accès AWS, obtenez les valeurs pour `AWS_ACCESS_KEY_ID`, `AWS_SECRET_ACCESS_KEY`, et `AWS_SESSION_TOKEN`. Pour en

savoir plus, consultez [Requesting temporary security credentials](#) (Demander d'informations d'identification temporaires de sécurité).

3. Déterminez l'emplacement de votre répertoire de journaux d'événements, à utiliser dans la commande `docker run`.
4. Créez l'image Docker à l'aide des fichiers du répertoire local, en utilisant le nom `glue/sparkui` et l'identification `latest`.

```
$ docker build -t glue/sparkui:latest .
```

5. Créez et démarrez le conteneur Docker.

Dans les commandes suivantes, utilisez les valeurs obtenues précédemment aux étapes 2 et 3.

- a. Pour créer le conteneur Docker à l'aide de vos informations d'identification utilisateur, utilisez une commande similaire à ce qui suit :

```
docker run -itd -e SPARK_HISTORY_OPTS="$SPARK_HISTORY_OPTS -
Dspark.history.fs.logDirectory=s3a://path_to_eventlog
-Dspark.hadoop.fs.s3a.access.key=AWS_ACCESS_KEY_ID -
Dspark.hadoop.fs.s3a.secret.key=AWS_SECRET_ACCESS_KEY"
-p 18080:18080 glue/sparkui:latest "/opt/spark/bin/spark-class
org.apache.spark.deploy.history.HistoryServer"
```

- b. Pour créer le conteneur Docker à l'aide d'informations d'identification temporaires, utilisez `org.apache.hadoop.fs.s3a.TemporaryAWSCredentialsProvider` en tant que fournisseur, et fournissez les valeurs d'identification obtenues à l'étape 2. Pour plus d'informations, consultez la section [Utilisation des informations d'identification de session avec un AWSCredentials fournisseur temporaire](#) dans la documentation Hadoop : intégration avec Amazon Web Services.

```
docker run -itd -e SPARK_HISTORY_OPTS="$SPARK_HISTORY_OPTS -
Dspark.history.fs.logDirectory=s3a://path_to_eventlog
-Dspark.hadoop.fs.s3a.access.key=AWS_ACCESS_KEY_ID -
Dspark.hadoop.fs.s3a.secret.key=AWS_SECRET_ACCESS_KEY
-Dspark.hadoop.fs.s3a.session.token=AWS_SESSION_TOKEN
-
Dspark.hadoop.fs.s3a.aws.credentials.provider=org.apache.hadoop.fs.s3a.TemporaryAWSCred
-p 18080:18080 glue/sparkui:latest "/opt/spark/bin/spark-class
org.apache.spark.deploy.history.HistoryServer"
```

 Note

Ces paramètres de configuration proviennent du [Hadoop-AWS Modules](#). Il se peut que vous ayez besoin d'ajouter une configuration spécifique en fonction des cas d'utilisation. Par exemple : les utilisateurs des régions isolées devront configurer le `spark.hadoop.fs.s3a.endpoint`.

6. Ouvrez `http://localhost:18080` dans votre navigateur pour afficher localement l'interface utilisateur Spark.

Surveillance à l'aide AWS Glue d'informations sur l'exécution des tâches

AWS Glue Job Run Insights est une fonctionnalité AWS Glue qui simplifie le débogage des tâches et l'optimisation de vos AWS Glue tâches. AWS Glue fournit l'[interface utilisateur Spark](#), ainsi que [CloudWatch des journaux et des indicateurs](#) pour surveiller vos AWS Glue tâches. Grâce à cette fonctionnalité, vous obtenez les informations suivantes concernant l'exécution de votre AWS Glue tâche :

- Numéro de ligne de votre script de AWS Glue tâche qui a échoué.
- L'action Spark exécutée en dernier dans le plan de requête Spark juste avant l'échec de votre tâche.
- Les événements d'exception Spark liés à l'échec présenté dans un flux de journal classé par ordre chronologique.
- L'analyse des causes racines et l'action recommandée (telle que le réglage de votre script) pour résoudre le problème.
- Les événements Spark courants (messages de journaux relatifs à une action Spark) avec une action recommandée qui traite la cause racine.

Toutes ces informations sont mises à votre disposition à l'aide de deux nouveaux flux de journaux dans les CloudWatch journaux de vos AWS Glue tâches.

Prérequis

La fonctionnalité AWS Glue Job Run Insights est disponible pour AWS Glue les versions 2.0, 3.0, 4.0 et 5.0. Vous pouvez suivre le [guide de migration](#) de vos tâches existantes pour les mettre à niveau à partir d'anciennes AWS Glue versions.

Activation des informations relatives à l'exécution des tâches pour une tâche AWS Glue ETL

Vous pouvez activer les informations relatives à l'exécution des tâches par le biais AWS Glue Studio de la CLI.

AWS Glue Studio

Lorsque vous créez une tâche via AWS Glue Studio, vous pouvez activer ou désactiver les informations relatives à l'exécution des tâches dans l'onglet Détails de la tâche. Vérifiez que la case Générer des informations sur les tâches est sélectionnée.

Requested number of workers

The number of workers you want AWS Glue to allocate to this job.

The maximums are 299 for G.1X and 149 for G.2X, and the minimum is 2.

☒ Generate job insights

AWS Glue will analyze your job runs and provide insights on how to optimize your jobs and the reasons for job failures.

Ligne de commande

Si vous créez une tâche via le CLI, vous pouvez démarrer l'exécution d'une tâche avec un seul nouveau [paramètre de tâche](#) : `--enable-job-insights = true`.

Par défaut, les flux de journaux des informations sur l'exécution de la tâche sont créés sous le même groupe de journaux par défaut utilisé par [AWS Glue journalisation continue](#), c'est-à-dire, `/aws-glue/jobs/logs-v2/`. Vous pouvez configurer un nom de groupe de journaux personnalisé, des filtres de journaux et des configurations de groupes de journaux à l'aide du même ensemble d'arguments que pour la journalisation continue. Pour plus d'informations, consultez la section [Activation de la journalisation continue pour les AWS Glue tâches](#).

Accès aux flux de journaux Job Run Insights dans CloudWatch

Lorsque la fonctionnalité des informations sur l'exécution de la tâche est activée, deux flux de journaux peuvent être créés en cas d'échec d'une exécution de tâche. Lorsqu'une tâche se termine correctement, aucun des flux n'est généré.

1. Flux de journaux d'analyse des exceptions : `<job-run-id>-job-insights-rca-driver`. Ce flux fournit les informations suivantes :
 - Numéro de ligne du script de AWS Glue tâche à l'origine de l'échec.

- L'action Spark exécutée en dernier dans le plan de requête Spark (DAG).
- Les événements chronologiques concis provenant du pilote Spark et les programmes d'exécution associés à l'exception. Vous pourrez trouver des détails tels que des messages d'erreur complets, la tâche Spark qui a échoué et l'ID de ses programmes d'exécution. Ces informations vous aident à vous concentrer sur le flux de journal du programme d'exécution spécifique pour une analyse plus approfondie si nécessaire.

2. Flux d'informations basé sur des règles :

- Analyse des causes racines et recommandations sur la manière de corriger les erreurs (telles que l'utilisation d'un paramètre de tâche spécifique pour optimiser les performances).
- Les événements Spark pertinents servant de base à l'analyse des causes racines et à une action recommandée.

Note

Le premier flux n'existera que si des événements Spark d'exception sont disponibles pour une exécution de tâche qui a échoué, et le second flux n'existera que si des informations sont disponibles pour l'exécution de la tâche qui a échoué. Par exemple, si votre tâche se termine correctement, aucun des flux ne sera généré. Si votre tâche échoue, mais qu'aucune règle définie par le service ne correspond à votre scénario d'échec, seul le premier flux sera généré.

Si la tâche est créée à partir de AWS Glue Studio, les liens vers les flux ci-dessus sont également disponibles sous l'onglet Détails de l'exécution du travail (Job run insights) sous la forme « Journaux d'erreurs concis et consolidés » et « Analyse des erreurs et conseils ».

Job run - jr_

Run details [Info](#)

✖ An error occurred while calling o134.pyWriteDynamicFrame. No such file or directory 's3://[REDACTED]',

Job name [REDACTED]	Run status ✔ Success	Glue version 2.0	Recent attempt 2
Start time May 17, 2021 1:10 PM	End time May 17, 2021 1:10 PM	Start-up time 4 seconds	Execution time 1 minute
Trigger name -	Last modified on May 17, 2021 1:10 PM	Security configuration -	Timeout 2880 minutes
Allocated capacity 10	Max capacity 10	Number of workers 10	Worker type G.1X
Cloudwatch logs All logs Output logs Error logs	Job run insights Info Concise and consolidated error logs Error analysis and guidance		

Exemple d'analyse de l'exécution des AWS Glue tâches

Dans cette section, nous vous présentons un exemple de la façon dont la fonctionnalité d'informations sur l'exécution de la tâche peut vous aider à résoudre un problème lié à votre tâche qui a échoué. Dans cet exemple, un utilisateur a oublié d'importer le module requis (tensorflow) dans une AWS Glue tâche pour analyser et créer un modèle d'apprentissage automatique à partir de ses données.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from pyspark.sql.types import *
from pyspark.sql.functions import udf,col

args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
```

```
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args['JOB_NAME'], args)

data_set_1 = [1, 2, 3, 4]
data_set_2 = [5, 6, 7, 8]

scoresDf = spark.createDataFrame(data_set_1, IntegerType())

def data_multiplier_func(factor, data_vector):
    import tensorflow as tf
    with tf.compat.v1.Session() as sess:
        x1 = tf.constant(factor)
        x2 = tf.constant(data_vector)
        result = tf.multiply(x1, x2)
        return sess.run(result).tolist()

data_multiplier_udf = udf(lambda x: data_multiplier_func(x, data_set_2),
    ArrayType(IntegerType(), False))
factoredDf = scoresDf.withColumn("final_value", data_multiplier_udf(col("value")))
print(factoredDf.collect())
```

La tâche échoue et, sans la fonctionnalité informations sur l'exécution de la tâche, vous ne voyez que ce message généré par Spark :

```
An error occurred while calling o111.collectToPython. Traceback (most
recent call last):
```

Le message est ambigu et limite votre expérience de débogage. Dans ce cas, cette fonctionnalité vous fournit des informations supplémentaires dans deux flux de CloudWatch journaux :

1. Le flux de journal job-insights-rca-driver :

- Événements d'exception : ce flux de journal fournit les événements d'exception Spark liés à l'échec collecté à partir du pilote Spark et de différents travailleurs distribués. Ces événements vous aident à comprendre la propagation chronologique de l'exception lorsque le code défectueux s'exécute sur les tâches Spark, les exécuteurs et les étapes réparties entre les travailleurs. AWS Glue
- Numéros de ligne: ce flux de journal identifie la ligne 21, qui a appelé à importer le module Python manquant à l'origine de l'échec. Il identifie également la ligne 24, l'appel à l'action Spark `collect()`, en tant que dernière ligne exécutée dans votre script.

Timestamp	Message
	No older events at this moment. Retry
2022-01-31T06:07:04.750-08:00	22/01/31 14:07:04 ERROR GlueExceptionAnalysisListener: [Glue Exception Analysis] Event: GlueExceptionAnalysisTaskFailed Failure Reason: Traceb...
2022-01-31T06:07:04.870-08:00	22/01/31 14:07:04 ERROR GlueExceptionAnalysisListener: [Glue Exception Analysis] Event: GlueExceptionAnalysisTaskFailed Stage ID: 0, Task ID: ...
2022-01-31T06:07:04.888-08:00	22/01/31 14:07:04 ERROR GlueExceptionAnalysisListener: [Glue Exception Analysis] Event: GlueExceptionAnalysisTaskFailed Stage ID: 0, Task ID: ...
2022-01-31T06:07:04.940-08:00	22/01/31 14:07:04 ERROR GlueExceptionAnalysisListener: [Glue Exception Analysis] Event: GlueExceptionAnalysisTaskFailed Stage ID: 0, Task ID: ...
2022-01-31T06:07:04.998-08:00	22/01/31 14:07:04 ERROR GlueExceptionAnalysisListener: [Glue Exception Analysis] Event: GlueExceptionAnalysisStageFailed Failure Reason: Job a...
2022-01-31T06:07:05.044-08:00	22/01/31 14:07:05 ERROR GlueExceptionAnalysisListener: [Glue Exception Analysis] Event: GlueExceptionAnalysisJobFailed Failure Reason: JobFail...
2022-01-31T06:07:05.105-08:00	22/01/31 14:07:05 ERROR GlueExceptionAnalysisListener: [Glue Exception Analysis] Root Cause Analysis Result: line 24 in script jobInsightsDemo... 22/01/31 14:07:05 ERROR GlueExceptionAnalysisListener: [Glue Exception Analysis] Root Cause Analysis Result: line 24 in script jobInsightsDemo.py.
2022-01-31T06:07:05.427-08:00	22/01/31 14:07:05 ERROR GlueExceptionAnalysisListener: [Glue Exception Analysis] Event: GlueETLJobExceptionEvent Failure Reason: Traceback (mo...
2022-01-31T06:07:05.430-08:00	22/01/31 14:07:05 ERROR GlueExceptionAnalysisListener: [Glue Exception Analysis] Last Executed Line number from script jobInsightsDemo.py: 33 22/01/31 14:07:05 ERROR GlueExceptionAnalysisListener: [Glue Exception Analysis] Last Executed Line number from script jobInsightsDemo.py: 33

2. Le flux de journal job-insights-rule-driver :

- Cause première et recommandation : Outre le numéro de ligne et le numéro de ligne de la dernière exécution correspondant à l'erreur dans votre script, ce flux de journal indique l'analyse des causes profondes et vous recommande de suivre le AWS Glue document et de configurer les paramètres de tâche nécessaires afin d'utiliser un module Python supplémentaire dans votre AWS Glue tâche.
- Événement récurrent : ce flux de journal affiche également l'événement d'exception Spark qui a été évalué avec la règle définie par le service afin d'en déduire la cause racine et de fournir une recommandation.

2022-01-31T06:07:05.499-08:00	22/01/31 14:07:05 ERROR Analyzer: 2022-01-31 14:07:05,499 ERROR [pool-2-thread-1] app.GlueJobAnalyzerApp\$ (Logging.scala:logError(9)) - [Glue ... 22/01/31 14:07:05 ERROR Analyzer: 2022-01-31 14:07:05,499 ERROR [pool-2-thread-1] app.GlueJobAnalyzerApp\$ (Logging.scala:logError(9)) - [Glue Insights]
	<pre>{ "details": { "time": 1643638025489, "rootCauseAnalysis": "Module that is referenced in Glue job was not found.", "action": "Include all modules used in Glue job, refer documentation on how to include external modules, https://aws.amazon.com/premiumsupport/knowledge-center/glue-version2-external-python-libraries/" }, "cause": { "module": "data_multiplier_func", "issue": "ModuleNotFoundError: No module named 'tensorflow'", "fileName": "jobInsightsDemo.py", "lineOfCode": 24 }, "basis": [{ "event": { "timestamp": 1643638024940, "failureReason": "Traceback (most recent call last):\n File \"/opt/amazon/spark/python/lib/pyspark.zip/pyspark/worker.py", line 377, in main\n process()\n File \"/opt/amazon/spark/python/lib/pyspark.zip/pyspark/worker.py", line 372, in process\n serializer.dump_stream(func(split_index, iterator),\n outfile)\n File \"/opt/amazon/spark/python/lib/pyspark.zip/pyspark/serializers.py", line 345, in dump_stream\n self.serializer.dump_stream(self._batched(iterator), stream)\n File \"/opt/amazon/spark/python/lib/pyspark.zip/pyspark/serializers.py", line 141, in dump_stream\n for obj in iterator:\n File \"/opt/amazon/spark/python/lib/pyspark.zip/pyspark/serializers.py", line 334, in _batched\n for item in iterator:\n File \"/opt/amazon/spark/python/lib/pyspark.zip/pyspark/worker.py", line 85, in <lambda>\n return lambda *a: f(*a)\n File \"/opt/amazon/spark/python/lib/pyspark.zip/pyspark/util.py", line 99, in wrapper\n return f(*args, **kwargs)\n File \"/tmp/jobInsightsDemo.py", line 31, in <lambda>\n File \"/tmp/jobInsightsDemo.py", line 24, in data_multiplier_func\nModuleNotFoundError: No module named 'tensorflow'\n", "stackTrace": [{ "declaringClass": "data_multiplier_func", "methodName": "ModuleNotFoundError: No module named 'tensorflow'", "fileName": "/tmp/jobInsightsDemo.py", "lineNumber": 24 }] }] } }</pre>

Surveillance avec Amazon CloudWatch

Vous pouvez surveiller AWS Glue en utilisant Amazon CloudWatch, qui collecte et traite les données brutes de AWS Glue en near-real-time métriques lisibles. Ces statistiques sont enregistrées pour

une durée de deux semaines afin de pouvoir accéder aux informations historiques vous permettant d'acquérir un meilleur point de vue sur la façon dont votre service ou application web s'exécute. Par défaut, AWS Glue les données des métriques sont envoyées CloudWatch automatiquement. Pour plus d'informations, consultez [Qu'est-ce qu'Amazon CloudWatch ?](#) dans le guide de CloudWatch l'utilisateur Amazon, et [AWS Glue métriques](#).

Journalisation continue

AWS Glue prend également en charge la journalisation continue en temps réel pour AWS Glue emplois. Lorsque la journalisation continue est activée pour une tâche, vous pouvez consulter les journaux en temps réel sur AWS Glue console ou le tableau de bord de CloudWatch la console. Pour de plus amples informations, veuillez consulter [Journalisation pour les AWS Glue emplois](#).

Métriques d'observabilité

Lorsque les métriques d'observabilité du Job sont activées, des Amazon CloudWatch métriques supplémentaires sont générées lors de l'exécution du job. Utiliser AWS Glue Des indicateurs d'observabilité pour obtenir des informations sur ce qui se passe au sein de votre AWS Glue pour améliorer le triage et l'analyse des problèmes.

Rubriques

- [Surveillance AWS Glue en utilisant les CloudWatch métriques Amazon](#)
- [Configuration des CloudWatch alarmes Amazon sur AWS Glue profils d'emploi](#)
- [Journalisation pour les AWS Glue emplois](#)
- [Surveillance avec AWS Glue Métriques d'observabilité](#)

Surveillance AWS Glue en utilisant les CloudWatch métriques Amazon

Vous pouvez profiler et surveiller AWS Glue opérations utilisant AWS Glue profileur d'emplois. Il collecte et traite les données brutes provenant de AWS Glue jobs dans des métriques lisibles en temps quasi réel stockées sur Amazon CloudWatch. Ces statistiques sont conservées et agrégées CloudWatch afin que vous puissiez accéder aux informations historiques pour avoir une meilleure idée des performances de votre application.

 Note

Des frais supplémentaires peuvent vous être facturés lorsque vous activez les indicateurs relatifs aux tâches et que CloudWatch des indicateurs personnalisés sont créés. Pour plus d'informations, consultez les [CloudWatch tarifs Amazon](#).

AWS Glue aperçu des métriques

Lorsque vous interagissez avec AWS Glue, il envoie des métriques à CloudWatch. Vous pouvez consulter ces statistiques à l'aide du AWS Glue console (méthode préférée), le tableau de bord de la CloudWatch console ou le AWS Command Line Interface (AWS CLI).

Pour consulter les statistiques à l'aide du AWS Glue tableau de bord de console

Vous pouvez afficher un résumé ou des graphiques détaillés des métriques pour une tâche ou des graphiques détaillés pour l'exécution d'une tâche.

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, choisissez Surveillance de l'exécution des tâches.
3. Dans Exécutions de tâches, choisissez Actions pour arrêter une tâche en cours d'exécution, afficher une tâche ou restaurer le signet d'une tâche.
4. Sélectionnez une tâche, puis choisissez Afficher les informations de l'exécution pour afficher des informations supplémentaires sur l'exécution de la tâche.

Pour consulter les statistiques à l'aide du tableau de bord de CloudWatch la console

Les métriques sont d'abord regroupées par espace de noms de service, puis par les différentes combinaisons de dimension au sein de chaque espace de noms.

1. Ouvrez la CloudWatch console à l'adresse <https://console.aws.amazon.com/cloudwatch/>.
2. Dans le panneau de navigation, sélectionnez Métriques.
3. Sélectionnez l'espace de noms Glue.

Pour consulter les statistiques à l'aide du AWS CLI

- À partir d'une invite de commande, utilisez la commande suivante :

```
aws cloudwatch list-metrics --namespace Glue
```

AWS Glue rapporte les métriques CloudWatch toutes les 30 secondes, et les tableaux de bord des CloudWatch métriques sont configurés pour les afficher toutes les minutes. Le AWS Glue les métriques représentent des valeurs delta par rapport aux valeurs précédemment déclarées. Le cas échéant, les tableaux de bord de métriques regroupent (additionnent) les valeurs de plages de 30 secondes pour obtenir une valeur pour la totalité de la dernière minute.

AWS Glue comportement des métriques pour les tâches Spark

AWS Glue les métriques sont activées lors de l'initialisation d'un `GlueContext` script et ne sont généralement mises à jour qu'à la fin d'une tâche Apache Spark. Elles représentent les valeurs regroupées sur l'ensemble des tâches Spark terminées jusqu'alors.

Cependant, les métriques Spark qui AWS Glue les transmissions vers CloudWatch sont généralement des valeurs absolues représentant l'état actuel au moment où elles sont signalées. AWS Glue les rapporte CloudWatch toutes les 30 secondes, et les tableaux de bord des métriques indiquent généralement la moyenne des points de données reçus au cours de la dernière minute.

AWS Glue les noms des métriques sont tous précédés de l'un des types de préfixes suivants :

- `glue.driver.` — Les métriques dont le nom commence par ce préfixe représentent soit AWS Glue des métriques agrégées à partir de tous les exécuteurs au niveau du pilote Spark, ou des métriques Spark correspondant au pilote Spark.
- `glue.executorId.` – L'`executorId` correspond au numéro d'un programme d'exécution Spark spécifique. Il correspond aux programmes d'exécution répertoriés dans les journaux.
- `glue.ALL.` - Les métriques dont les noms commencent par ce préfixe regroupent des valeurs de tous les programmes d'exécution Spark.

AWS Glue métriques

AWS Glue établit le profil et envoie les métriques suivantes CloudWatch toutes les 30 secondes, et le tableau de bord AWS Glue des métriques les indique une fois par minute :

Métrique	Description
<code>glue.driver.aggregate.bytes</code> Read	Nombre d'octets lus à partir de toutes les sources de données par toutes les tâches Spark exécutées dans tous les programmes d'exécution. Dimensions valides : JobName (le nom du AWS Glue Job), JobRunId (l' JobRun ID ouALL) et Type (le nombre). Statistiques valides : SUM. Cette métrique est une valeur delta par rapport à la dernière valeur signalée. Par conséquent, sur le tableau de bord AWS Glue des mesures, une statistique SUM est utilisée pour l'agrégation. Unité : octets Peut être utilisé pour contrôler ce qui suit : • Octets lus. • Progrès de la tâche. • Source de données JDBC. • Problèmes de marque-page de la tâche. • Variation entre les exécutions de tâches. Cette métrique peut être utilisée de la même manière que la métrique <code>glue.ALL.s3.filesystem.read_bytes</code> , à la différence qu'elle est mise à jour à la fin d'une tâche Spark et qu'elle capture également les sources de données non S3.
<code>glue.driver.aggregate.elapsedTime</code>	Le temps écoulé ETL en millisecondes (n'inclut pas les temps d'amorçage de la tâche).

Métrique	Description
	Dimensions valides : JobName (le nom du AWS Glue Job), JobRunId (l' JobRun ID ouALL) et Type (le nombre). Statistiques valides : SUM. Cette métrique est une valeur delta par rapport à la dernière valeur signalée. Par conséquent, sur le tableau de bord AWS Glue des mesures, une statistique SUM est utilisée pour l'agrégation. Unité : millisecondes Peut être utilisé pour déterminer combien le temps moyen requis pour une exécution de tâche. Voici quelques façons d'utiliser les données : • Définissez des alarmes pour les ralentisseurs. • Mesurez l'écart entre les exécutions de tâches.

Métrique	Description
<code>glue.driver.aggregate.numCompletedStages</code>	Le nombre d'étapes terminées dans la tâche. Dimensions valides : JobName (le nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL) et Type (le nombre). Statistiques valides : SUM. Cette métrique est une valeur delta par rapport à la dernière valeur signalée. Par conséquent, sur le tableau de bord AWS Glue des mesures, une statistique SUM est utilisée pour l'agrégation. Unité : nombre Peut être utilisé pour contrôler ce qui suit : • Progrès de la tâche. • Chronologie par étape de l'exécution des tâches, en cas de corrélation avec d'autres métriques. Voici quelques façons d'utiliser les données : • Identifiez les étapes exigeantes dans l'exécution d'une tâche. • Définissez des alarmes pour les pics corrélés (étapes exigeantes) à travers les exécutions de tâches.

Métrique	Description
<code>glue.driver.aggregate.numCompletedTasks</code>	Le nombre de tâches terminées dans la tâche. Dimensions valides : JobName (le nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL) et Type (le nombre). Statistiques valides : SUM. Cette métrique est une valeur delta par rapport à la dernière valeur signalée. Par conséquent, sur le tableau de bord AWS Glue des mesures, une statistique SUM est utilisée pour l'agrégation. Unité : nombre Peut être utilisé pour contrôler ce qui suit : • Progrès de la tâche. • Parallélisme au sein d'une étape.

Métrique	Description
<code>glue.driver.aggregate.numFailedTasks</code>	Nombre de tâches ayant échoué. Dimensions valides : JobName (le nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL) et Type (le nombre). Statistiques valides : SUM. Cette métrique est une valeur delta par rapport à la dernière valeur signalée. Par conséquent, sur le tableau de bord AWS Glue des mesures, une statistique SUM est utilisée pour l'agrégation. Unité : nombre Peut être utilisé pour contrôler ce qui suit : • Anomalies de données qui provoquent l'échec des tâches de la tâche. • Anomalies de cluster qui provoquent l'échec des tâches de la tâche. • Anomalies de script qui provoquent l'échec des tâches de la tâche. Les données peuvent être utilisées pour définir des alarmes pour des échecs accrus qui pourraient suggérer des anomalies dans les données, les clusters ou les scripts.

Métrique	Description
<code>glue.driver.aggregate.numKilledTasks</code>	Nombre de tâches supprimées. Dimensions valides : JobName (le nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL) et Type (le nombre). Statistiques valides : SUM. Cette métrique est une valeur delta par rapport à la dernière valeur signalée. Par conséquent, sur le tableau de bord AWS Glue des mesures, une statistique SUM est utilisée pour l'agrégation. Unité : nombre Peut être utilisé pour contrôler ce qui suit : • Anomalies dans le biais des données qui se traduisent par des exceptions (OOMs) qui tuent des tâches. • Anomalies du script qui entraînent des exceptions (OOMs) qui tuent des tâches. Voici quelques façons d'utiliser les données : • Définissez des alarmes pour les échecs accrus indiquant des anomalies des données. • Définissez des alarmes pour les échecs accrus indiquant des anomalies de cluster. • Définissez des alarmes pour les échecs accrus indiquant des anomalies de script.

Métrique	Description
<code>glue.driver.aggregate.recordsRead</code>	Nombre d'enregistrements lus à partir de toutes les sources de données par toutes les tâches Spark terminées exécutées dans tous les programmes d'exécution. Dimensions valides : JobName (le nom du AWS Glue Job), JobRunId (l' JobRun ID ouALL) et Type (le nombre). Statistiques valides : SUM. Cette métrique est une valeur delta par rapport à la dernière valeur signalée. Par conséquent, sur le tableau de bord AWS Glue des mesures, une statistique SUM est utilisée pour l'agrégation. Unité : nombre Peut être utilisé pour contrôler ce qui suit : • Enregistrements lus. • Progrès de la tâche. • Source de données JDBC. • Problèmes de marque-page de la tâche. • Asymétrie dans les exécutions de tâches au fil des jours. Cette métrique peut être utilisée de manière similaire à la métrique <code>glue.ALL.s3.filesystem.read_bytes</code> , à la différence qu'elle est mise à jour à la fin d'une tâche Spark.

Métrique	Description
<code>glue.driver.aggregate.shuffleBytesWritten</code>	Nombre d'octets écrits par tous les exécuteurs pour mélanger les données entre eux depuis le rapport précédent (agrégé par le tableau de bord des AWS Glue mesures sous la forme du nombre d'octets écrits à cette fin au cours de la minute précédente). Dimensions valides : JobName (le nom du AWS Glue Job), JobRunId (l' JobRun ID ouALL) et Type (le nombre). Statistiques valides : SUM. Cette métrique est une valeur delta par rapport à la dernière valeur signalée. Par conséquent, sur le tableau de bord AWS Glue des mesures, une statistique SUM est utilisée pour l'agrégation. Unité : octets Peut être utilisé pour contrôler le remaniement de données dans les tâches (jointures volumineuses, GroupBy, répartition, coalesce). Voici quelques façons d'utiliser les données : • Repartitionnez ou décompressez les fichiers d'entrée volumineux avant un traitement ultérieur. • Repartitionnez les données de manière plus uniforme pour éviter les raccourcis clavier. • Filtrez préalablement les données avant les jointures ou les opérations GroupBy.

Métrique	Description
<code>glue.driver.aggregate.shuffleLocalBytesRead</code>	Nombre d'octets lus par tous les exécuteurs pour transférer des données entre eux depuis le rapport précédent (agrégé par le tableau de bord des AWS Glue mesures sous la forme du nombre d'octets lus à cette fin au cours de la minute précédente). Dimensions valides : JobName (le nom du AWS Glue Job), JobRunId (l' JobRun ID ouALL) et Type (le nombre). Statistiques valides : SUM. Cette métrique est une valeur delta par rapport à la dernière valeur signalée. Par conséquent, sur le tableau de bord AWS Glue des mesures, une statistique SUM est utilisée pour l'agrégation. Unité : octets Peut être utilisé pour contrôler le remaniement de données dans les tâches (jointures volumineuses, GroupBy, répartition, coalesce). Voici quelques façons d'utiliser les données : • Repartitionnez ou décompressez les fichiers d'entrée volumineux avant un traitement ultérieur. • Repartitionnez les données de manière plus uniforme à l'aide des raccourcis clavier. • Filtrez préalablement les données avant les jointures ou les opérations GroupBy.

Métrique	Description
<code>glue.driver.BlockManager.disk.diskSpaceUsed_MB</code>	Nombre de mégaoctets d'espace disque utilisés sur tous les programmes d'exécution. Dimensions valides : JobName (le nom du AWS Glue Job), JobRunId (l' JobRun identifiant ouALL) et Type (la jauge). Statistiques valides : moyenne Il s'agit d'une métrique Spark, rapportée en tant que valeur absolue. Unité : mégaoctets Peut être utilisé pour contrôler ce qui suit : • Espace disque utilisé pour les blocs qui représentent des partitions RDD mises en cache. • Espace disque utilisé pour les blocs qui représentent des sorties de remaniement intermédiaire. • Espace disque utilisé pour les blocs qui représentent des diffusions. Voici quelques façons d'utiliser les données : • Identifiez les échecs de tâche dus à une utilisation accrue du disque. • Identifiez les larges partitions qui entraînent un déversement ou un remaniement. • Augmentez la capacité DPU allouée pour corriger ces problèmes.

Métrique	Description
<code>glue.driver.ExecutorAllocationManager.executors.numberAllExecutors</code>	Le nombre de programmes d'exécution de tâches actifs en cours d'exécution. Dimensions valides : JobName (le nom du AWS Glue Job), JobRunId (l' JobRun identifiant ouALL) et Type (la jauge). Statistiques valides : moyenne Il s'agit d'une métrique Spark, rapportée en tant que valeur absolue. Unité : nombre Peut être utilisé pour contrôler ce qui suit : • Activité de la tâche. • Programmes d'exécution en retard (avec uniquement quelques programmes d'exécution en cours d'exécution) • Parallélisme actuel au niveau du programme d'exécution. Voici quelques façons d'utiliser les données : • Repartitionnez ou décompressez au préalable les fichiers d'entrée volumineux si le cluster est sous-utilisé. • Identifiez les retards d'exécution de l'étape ou de la tâche dus à des scénarios de ralentissement. • • Comparez avec les <code>numberMaxNeeded</code> exécuteurs pour mieux comprendre le backlog et mieux approvisionner. DPU

Métrique	Description
<code>glue.driver.ExecutorAllocationManager.executors.numberMaxNeededExecutors</code>	Nombre maximal de programmes d'exécution de tâches (en cours d'exécution et en attente) nécessaires pour satisfaire la charge actuelle. Dimensions valides : JobName (le nom du AWS Glue Job), JobRunId (l' JobRun identifiant ouALL) et Type (la jauge). Statistiques valides : maximum Il s'agit d'une métrique Spark, rapportée en tant que valeur absolue. Unité : nombre Peut être utilisé pour contrôler ce qui suit : • Activité de la tâche. • Parallélisme actuel au niveau du programme d'exécution et backlog de tâches en attente qui ne sont pas encore planifiées en raison de l'indisponibilité des programmes d'exécution, en raison de la capacité du DPU ou de l'échec/la suppression des programmes d'exécution. Voici quelques façons d'utiliser les données : • Identifiez la mise en attente ou le backlog de la file d'attente de planification. • Identifiez les retards d'exécution de l'étape ou de la tâche dus à des scénarios de ralentissement. • Comparez avec <code>numberAllExecutors</code> pour comprendre le backlog afin de mieux approvisionner. DPUs

Métrique	Description
	Augmentez la capacité de DPU allouée pour corriger le backlog des programmes d'exécution en attente.

Métrique	Description
<code>glue.driver.jvm.heap.usage</code>	La fraction de mémoire utilisée par la pile de la JVM pour ce pilote (échelle : 0-1) pour le pilote, un programme d'exécution identifié par <code>executorId</code> ou TOUS les programmes d'exécution.
<code>glue.executorId.jvm.heap.usage</code>	Dimensions valides : <code>JobName</code> (le nom du AWS Glue Job), <code>JobRunId</code> (l' JobRun identifiant ou ALL) et <code>Type</code> (la jauge).
<code>glue.ALL.jvm.heap.usage</code>	Statistiques valides : moyenne Il s'agit d'une métrique Spark, rapportée en tant que valeur absolue. Unité : pourcentage Peut être utilisé pour contrôler ce qui suit : - Utilisation out-of-memory <code>glue.driver.jvm.heap.usage</code> des conditions du conducteur (OOM). - Utilisation des out-of-memory conditions de l'exécuteur (OOM). <code>glue.ALL.jvm.heap.usage</code> Voici quelques façons d'utiliser les données : - Identifiez les ID et les étapes des programmes d'exécution consommant de la mémoire. - Identifiez les ID et les étapes des programmes d'exécution en retard. - Identifiez un out-of-memory état du conducteur (OOM). - Identifiez une out-of-memory condition d'exécuteur (OOM) et obtenez l'ID d'exécuteur correspondant

Métrique	Description
	afin de pouvoir obtenir une trace de pile à partir du journal de l'exécuteur. • Identifiez les fichiers ou les partitions susceptibles de présenter une distorsion des données, ce qui peut entraîner des retards ou out-of-memory des conditions (). OOMs

Métrique	Description
<code>glue.driver.jvm.heap.used</code>	le nombre d'octets de mémoire utilisés par la pile JVM pour le pilote, le programme d'exécution identifié par <code>executorId</code>, ou TOUS les programmes d'exécution. Dimensions valides : <code>JobName</code> (le nom du AWS Glue Job), <code>JobRunId</code> (l' JobRun identifiant ou <code>ALL</code>) et <code>Type</code> (la jauge). Statistiques valides : moyenne Il s'agit d'une métrique Spark, rapportée en tant que valeur absolue. Unité : octets Peut être utilisé pour contrôler ce qui suit : • <code>out-of-memoryConditions</code> de conduite (OOM). • <code>out-of-memoryConditions</code> de l'exécuteur (OOM). Voici quelques façons d'utiliser les données : • Identifiez les ID et les étapes des programmes d'exécution consommant de la mémoire. • Identifiez les ID et les étapes des programmes d'exécution en retard. • Identifiez un <code>out-of-memory</code> état du conducteur (OOM). • Identifiez une <code>out-of-memory</code> condition d'exécuteur (OOM) et obtenez l'ID d'exécuteur correspondant afin de pouvoir obtenir une trace de pile à partir du journal de l'exécuteur. • Identifiez les fichiers ou les partitions susceptibles de présenter une distorsion des données, ce qui
<code>glue.executorId.jvm.heap.used</code>	
<code>glue.ALL.jvm.heap.used</code>	

Métrique	Description
	peut entraîner des retards ou out-of-memory des conditions (). OOMs

Métrique	Description
<code>glue.driver.s3.filesystem.read_bytes</code>	Le nombre d'octets lus depuis Amazon S3 par le pilote, un exécuteur identifié par ExecutorID ou TOUS les exécuteurs depuis le rapport précédent (agrégé par le tableau de bord des métriques sous la forme du nombre d'octets lus AWS Glue au cours de la minute précédente).
<code>glue.executorId.s3.filesystem.read_bytes</code>	Dimensions valides : JobName, JobRunId, et Type (jauge).
<code>glue.ALL.s3.filesystem.read_bytes</code>	Statistiques valides : SUM. Cette métrique est une valeur delta par rapport à la dernière valeur signalée. Par conséquent, sur le tableau de bord AWS Glue des mesures, une statistique SUM est utilisée pour l'agrégation. La zone située sous la courbe sur le tableau de bord AWS Glue des métriques peut être utilisée pour comparer visuellement les octets lus lors de deux exécutions de tâches différentes. Unité : octets. Peut être utilisé pour contrôler ce qui suit : • Déplacement de données ETL. • Progrès de la tâche. • Problèmes de marque-page de tâche (données traitées, retraitées et ignorées). • Comparaison des lectures par rapport au taux d'ingestion à partir de sources de données externes. • Variation entre les exécutions de tâches. Les données résultantes peuvent être utilisées pour ce qui suit :

Métrique	Description
	• Planification des capacités de DPU. • Paramétrage d'alarmes pour les pics importants ou les creux au niveau des données lues pour les exécutions de tâches et les étapes des tâches.

Métrique	Description
<code>glue.driver.s3.filesystem.write_bytes</code> <code>glue.executorId.s3.filesystem.write_bytes</code> <code>glue.ALL.s3.filesystem.write_bytes</code>	Le nombre d'octets écrits sur Amazon S3 par le pilote, un exécuteur identifié par ExecutorID ou TOUS les exécuteurs depuis le rapport précédent (agrégé par le tableau de bord des métriques sous la forme du nombre d'octets écrits AWS Glue au cours de la minute précédente). Dimensions valides : JobName, JobRunId, et Type (jauge). Statistiques valides : SUM. Cette métrique est une valeur delta par rapport à la dernière valeur signalée. Par conséquent, sur le tableau de bord AWS Glue des mesures, une statistique SUM est utilisée pour l'agrégation. La zone située sous la courbe sur le tableau de bord AWS Glue des métriques peut être utilisée pour comparer visuellement les octets écrits lors de deux exécutions de tâches différentes. Unité : octets Peut être utilisé pour contrôler ce qui suit : • Déplacement de données ETL. • Progrès de la tâche. • Problèmes de marque-page de tâche (données traitées, retraitées et ignorées). • Comparaison des lectures par rapport au taux d'ingestion à partir de sources de données externes. • Variation entre les exécutions de tâches. Voici quelques façons d'utiliser les données : • Planification des capacités de DPU.

Métrique	Description
	• Paramétrage d'alarmes pour les pics importants ou les creux au niveau des données lues pour les exécutions de tâches et les étapes des tâches.
<code>glue.driver.streaming.numRecords</code>	Nombre d'enregistrements reçus dans un micro-lot. Cette métrique n'est disponible que pour les jobs de AWS Glue streaming dotés de AWS Glue la version 2.0 ou supérieure. Dimensions valides : JobName (le nom de la AWS Glue tâche), JobRunId (l' JobRun identifiant ou ALL) et Type (nombre). Statistiques valides : somme, minimum, maximum, moyenne, percentile Unité : nombre Peut être utilisé pour contrôler ce qui suit : • Enregistrements lus. • Progrès de la tâche.

Métrique	Description
<code>glue.driver.streaming.batchProcessingTimeInMs</code>	Temps nécessaire pour traiter les lots en millisecondes. Cette métrique n'est disponible que pour les jobs de AWS Glue streaming dotés de AWS Glue la version 2.0 ou supérieure. Dimensions valides : JobName (le nom de la AWS Glue tâche), JobRunId (l' JobRun identifiant ou ALL) et Type (nombre). Statistiques valides : somme, minimum, maximum, moyenne, percentile Unité : nombre Peut être utilisé pour contrôler ce qui suit : • Progrès de la tâche. • Performances de script.

Métrique	Description
<code>glue.driver.system.cpuSystemLoad</code>	La fraction de chargement du système UC utilisée (échelle : 0-1) par le pilote, un programme d'exécution identifié par <code>executorId</code> ou tous les programmes d'exécution.
<code>glue.executorId.system.cpuSystemLoad</code>	Dimensions valides : <code>JobName</code> (le nom de la AWS Glue tâche), <code>JobRunId</code> (l' JobRun identifiant ou ALL) et <code>Type</code> (la jauge).
<code>glue.ALL.system.cpuSystemLoad</code>	Statistiques valides : moyenne Cette métrique est rapportée en tant que valeur absolue. Unité : pourcentage Peut être utilisé pour contrôler ce qui suit : • Charge de l'UC du pilote. • Charge de l'UC du programme d'exécution. • Détection des programmes d'exécution ou des stages liés à l'UC ou liés à l'IO dans une tâche. Voici quelques façons d'utiliser les données : • Planification de la capacité DPU ainsi que les mesures d'IO (octets de lecture/octets de remaniement, parallélisme des tâches) et nombre maximal de métriques de programmes d'exécution nécessaires. • Identifier le ratio UC/IO lié. Cela permet de répartir et d'augmenter la capacité allouée pour les tâches de longue durée avec des jeux de données pouvant être divisés ayant une utilisation moins élevée de l'UC.

Dimensions pour les AWS Glue métriques

AWS Glue les métriques utilisent l'espace de AWS Glue noms et fournissent des métriques pour les dimensions suivantes :

Dimension	Description
JobName	Cette dimension filtre les métriques de toutes les exécutions d'une AWS Glue tâche spécifique.
JobRunId	Cette dimension filtre les métriques d'une AWS Glue tâche spécifique exécutée par un JobRun ID, ou ALL.
Type	Cette dimension filtre les métriques par count (un nombre agrégé) ou gauge (une valeur à un moment donné).

Pour plus d'informations, consultez le [guide de CloudWatch l'utilisateur Amazon](#).

Configuration des CloudWatch alarmes Amazon sur AWS Glue profils d'emploi

AWS Glue les statistiques sont également disponibles sur Amazon CloudWatch. Vous pouvez configurer des alarmes sur n'importe quel AWS Glue métrique pour les tâches planifiées.

Voici quelques scénarios courants de configuration d'alarmes :

- Tâches à court de mémoire (OOM) : définissez une alarme lorsque l'utilisation de la mémoire dépasse la moyenne normale pour le pilote ou un exécuteur d'un AWS Glue travail.
- Exécuteurs retardés : définissez une alarme lorsque le nombre d'exécuteurs tombe en dessous d'un certain seuil pendant une longue période dans un AWS Glue travail.
- Retard ou retraitement des données : comparez les indicateurs des tâches individuelles d'un flux de travail à l'aide d'une expression CloudWatch mathématique. Vous pouvez ensuite déclencher une alarme sur la valeur résultant de l'expression (comme le ratio entre les octets écrits par une tâche et les octets lus par une tâche suivante).

Pour obtenir des instructions détaillées sur la configuration des alarmes, consultez la section [Créer ou modifier une CloudWatch alarme](#) dans le [guide de l'utilisateur Amazon CloudWatch Events](#).

Pour les scénarios de surveillance et de débogage utilisant CloudWatch, voir [Surveillance et débogage des tâches](#).

Journalisation pour les AWS Glue emplois

Dans la AWS Glue version 5.0, toutes les tâches disposent de fonctionnalités de journalisation en temps réel. En outre, vous pouvez définir des options de configuration personnalisées pour adapter le comportement de journalisation. Ces options incluent la définition du nom du groupe de Amazon CloudWatch journaux, du préfixe du flux de Amazon CloudWatch journal (qui précédera l'ID et l'ID AWS Glue d'exécution de la tâche) et driver/executor du modèle de conversion des journaux pour les messages de journal. Ces configurations vous permettent d'agréger les journaux dans des groupes de Amazon CloudWatch journaux personnalisés avec différentes politiques d'expiration. En outre, vous pouvez analyser les journaux plus efficacement en utilisant des préfixes de flux de journaux et des modèles de conversion personnalisés. Ce niveau de personnalisation vous permet d'optimiser la gestion et l'analyse des journaux en fonction de vos besoins spécifiques.

Comportement de journalisation en AWS Glue version 5.0

Par défaut, les journaux du système, les journaux du démon Spark et les journaux de l'utilisateur AWS Glue sont écrits dans le groupe de /aws-glue/jobs/error journaux. Amazon CloudWatch D'autre part, les journaux utilisateur stdout (sortie standard) et stderr (erreur standard) sont écrits dans le /aws-glue/jobs/output groupe de journaux par défaut.

Journalisation personnalisée

Vous pouvez personnaliser le groupe de journaux par défaut et les préfixes de flux de journaux à l'aide des arguments de tâche suivants :

- `--custom-logGroup-prefix`: vous permet de spécifier un préfixe personnalisé pour les groupes de /aws-glue/jobs/output journaux /aws-glue/jobs/error et. Si vous fournissez un préfixe personnalisé, les noms des groupes de journaux seront au format suivant :
 - /aws-glue/jobs/error sera *<customer prefix>/error*
 - /aws-glue/jobs/output sera *<customer prefix>/output*
- `--custom-logStream-prefix`: vous permet de spécifier un préfixe personnalisé pour les noms des flux de journaux au sein des groupes de journaux. Si vous fournissez un préfixe personnalisé, les noms des flux de journaux seront au format suivant :
 - jobrunid-driver sera *<customer log stream>-driver*
 - jobrunid-executorNum sera *<customer log stream>-executorNum*

Règles de validation et limites pour les préfixes personnalisés :

- Le nom complet du flux de log doit comporter entre 1 et 512 caractères.
- Le préfixe personnalisé lui-même est limité à 400 caractères.
- Le préfixe personnalisé doit correspondre au modèle d'expression régulière ``[^ : *] *`` (les caractères spéciaux autorisés sont « `_` », « `-` » et « `/` »).

Journalisation des messages spécifiques aux applications à l'aide de l'enregistreur de script personnalisé

Vous pouvez utiliser l' AWS Glue enregistreur pour enregistrer tous les messages spécifiques à l'application dans le script qui sont envoyés en temps réel au flux de journal du pilote.

L'exemple suivant illustre un script Python.

```
from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)
logger = glueContext.get_logger()
logger.info("info message")
logger.warn("warn message")
logger.error("error message")
```

L'exemple suivant illustre un script Scala.

```
import com.amazonaws.services.glue.log.GlueLogger

object GlueApp {
  def main(sysArgs: Array[String]) {
    val logger = new GlueLogger
    logger.info("info message")
    logger.warn("warn message")
    logger.error("error message")
  }
}
```

Activation de la barre de progression pour afficher la progression d'une tâche

AWS Glue fournit une barre de progression en temps réel sous le flux du `JOB_RUN_ID-progress-bar` journal pour vérifier l'état AWS Glue d'exécution des tâches. Actuellement, il prend en charge uniquement les tâches qui initialisent `glueContext`. Si vous exécutez une tâche Spark pure sans l'initialiser `glueContext`, la barre de AWS Glue progression n'apparaît pas.

La barre de progression indique une mise à jour de la progression suivante toutes les 5 secondes.

```
Stage Number (Stage Name): > (numCompletedTasks + numActiveTasks) /  
totalNumOfTasksInThisStage]
```

Configuration de sécurité avec Amazon CloudWatch journalisation

Lorsqu'une configuration de sécurité est activée pour les Amazon CloudWatch journaux, AWS Glue crée des groupes de journaux avec des modèles de dénomination spécifiques qui incorporent le nom de la configuration de sécurité.

Dénomination des groupes de journaux avec configuration de sécurité

Les groupes de journaux par défaut et personnalisés seront les suivants :

- Groupe de journaux d'erreurs par défaut : `/aws-glue/jobs/Security-Configuration-Name-role/glue-job-role/error`
- Groupe de journaux de sortie par défaut : `/aws-glue/jobs/Security-Configuration-Name-role/glue-job-role/output`
- Groupe de journaux d'erreurs personnalisé (AWS Glue 5.0) : `custom-log-group-prefix/Security-Configuration-Name-role/glue-job-role/error`
- Groupe de journaux de sortie personnalisé (AWS Glue 5.0) : `custom-log-group-prefix/Security-Configuration-Name-role/glue-job-role/output`

Autorisations IAM nécessaires

Vous devez ajouter cette logs : `AssociateKmsKey` autorisation aux autorisations de votre rôle IAM, si vous activez une configuration de sécurité avec Amazon CloudWatch Logs. Si cette autorisation n'est pas incluse, la journalisation continue sera désactivée.

De plus, pour configurer le chiffrement des Amazon CloudWatch journaux, suivez les instructions de la section [Chiffrer les données des Amazon CloudWatch journaux dans les journaux à l'aide AWS Key Management Service](#) du guide de l'utilisateur Amazon Amazon CloudWatch Logs.

Informations supplémentaires

Pour plus d'informations sur la création de configurations de sécurité, consultez [la section Gestion des configurations de sécurité sur la AWS Glue console](#).

Rubriques

- [Activation de la journalisation continue pour les tâches AWS Glue 4.0 et antérieures](#)
- [Afficher les journaux des AWS Glue offres d'emploi](#)

Activation de la journalisation continue pour les tâches AWS Glue 4.0 et antérieures

Note

Dans les versions AWS Glue 4.0 et antérieures, la journalisation continue était une fonctionnalité disponible. Cependant, avec l'introduction de la AWS Glue version 5.0, toutes les tâches disposent d'une fonctionnalité de journalisation en temps réel. Pour plus de détails sur les fonctionnalités de journalisation et les options de configuration de la AWS Glue version 5.0, consultez la section [Journalisation des AWS Glue tâches](#).

Vous pouvez activer la journalisation continue à l'aide de la AWS Glue console ou via le AWS Command Line Interface (AWS CLI).

Vous pouvez activer la journalisation continue lorsque vous créez une nouvelle tâche, modifiez une tâche existante ou que vous l'activez via le AWS CLI.

Vous pouvez également spécifier des options de configuration personnalisées telles que le nom du groupe de Amazon CloudWatch journaux, le préfixe du flux de CloudWatch journal avant l' driver/ executor ID AWS Glue d'exécution de la tâche et le modèle de conversion des journaux pour les messages de journal. Ces configurations vous permettent de définir des journaux agrégés dans des groupes de CloudWatch journaux personnalisés avec différentes politiques d'expiration, et de les analyser plus en détail à l'aide de préfixes de flux de journaux et de modèles de conversion personnalisés.

Rubriques

- [À l'aide du AWS Management Console](#)
- [Journalisation des messages spécifiques aux applications à l'aide de l'enregistreur de script personnalisé](#)
- [Activation de la barre de progression pour afficher la progression d'une tâche](#)
- [Configuration de sécurité avec la journalisation continue](#)

À l'aide du AWS Management Console

Procédez comme suit pour utiliser la console afin d'activer la journalisation continue lors de la création ou de la modification d'une AWS Glue tâche.

Pour créer une nouvelle AWS Glue tâche grâce à la journalisation continue

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le volet de navigation, sélectionnez ETL jobs.
3. Choisissez Visual ETL.
4. Dans l'onglet Détails du Job, développez la section Propriétés avancées.
5. Sous Journalisation continue, sélectionnez Activer les connexions CloudWatch.

Pour activer la journalisation continue d'une AWS Glue tâche existante

1. Ouvrez la AWS Glue console à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le volet de navigation, sélectionnez Tâches.
3. Choisissez une tâche existante à partir de la liste des Tâches.
4. Choisissez Action, Modifier la tâche.
5. Dans l'onglet Détails du Job, développez la section Propriétés avancées.
6. Sous Journalisation continue, sélectionnez Activer les connexions CloudWatch.

À l'aide du AWS CLI

Pour activer la journalisation continue, vous devez transmettre les paramètres d'une tâche à une AWS Glue tâche. Transmettez les paramètres de tâche spéciaux suivants, similaires aux autres paramètres de AWS Glue tâche. Pour de plus amples informations, veuillez consulter [Utilisation des paramètres des tâches dans les tâches AWS Glue](#).

```
'--enable-continuous-cloudwatch-log': 'true'
```

Vous pouvez spécifier un nom de groupe de CloudWatch journaux Amazon personnalisé. Si aucune valeur n'est spécifiée, le nom par défaut du groupe de journaux est `/aws-glue/jobs/logs-v2`.

```
'--continuous-log-logGroup': 'custom_log_group_name'
```

Vous pouvez spécifier un préfixe de flux de CloudWatch journal Amazon personnalisé. Si aucune valeur n'est spécifiée, le préfixe de flux de journal par défaut est l'ID d'exécution du travail.

```
'--continuous-log-logStreamPrefix': 'custom_log_stream_prefix'
```

Vous pouvez spécifier un modèle de conversion de journalisation continue personnalisé. Si aucune valeur n'est spécifiée, le modèle de conversion par défaut est `%d{yy/MM/dd HH:mm:ss} %p %c{1}: %m%n`. Notez que le modèle de conversion s'applique uniquement aux journaux des pilotes et des programmes d'exécution. Cela n'affecte pas la barre de progression AWS Glue .

```
'--continuous-log-conversionPattern': 'custom_log_conversion_pattern'
```

Journalisation des messages spécifiques aux applications à l'aide de l'enregistreur de script personnalisé

Vous pouvez utiliser l' AWS Glue enregistreur pour enregistrer tous les messages spécifiques à l'application dans le script qui sont envoyés en temps réel au flux de journal du pilote.

L'exemple suivant illustre un script Python.

```
from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)
logger = glueContext.get_logger()
logger.info("info message")
logger.warn("warn message")
logger.error("error message")
```

L'exemple suivant illustre un script Scala.

```
import com.amazonaws.services.glue.log.GlueLogger

object GlueApp {
  def main(sysArgs: Array[String]) {
    val logger = new GlueLogger
    logger.info("info message")
    logger.warn("warn message")
    logger.error("error message")
  }
}
```

Activation de la barre de progression pour afficher la progression d'une tâche

AWS Glue fournit une barre de progression en temps réel sous le flux du JOB_RUN_ID-progress-bar journal pour vérifier l'état AWS Glue d'exécution des tâches. Actuellement, il prend en charge uniquement les tâches qui initialisent glueContext. Si vous exécutez une tâche Spark pure sans l'initialiser glueContext, la barre de AWS Glue progression n'apparaît pas.

La barre de progression indique une mise à jour de la progression suivante toutes les 5 secondes.

```
Stage Number (Stage Name): > (numCompletedTasks + numActiveTasks) /
totalNumOfTasksInThisStage]
```

Configuration de sécurité avec la journalisation continue

Si une configuration de sécurité est activée pour CloudWatch les journaux, AWS Glue créera un groupe de journaux nommé comme suit pour les journaux continus :

```
<Log-Group-Name>-<Security-Configuration-Name>
```

Les groupes de journaux par défaut et personnalisés seront les suivants :

- Le groupe de journaux continus par défaut sera /aws-glue/jobs/error-*<Security-Configuration-Name>*
- Le groupe de journaux continus personnalisé sera *<custom-log-group-name>*-*<Security-Configuration-Name>*

Vous devez ajouter les autorisations logs:AssociateKmsKey à votre rôle IAM, si vous activez une configuration de sécurité avec CloudWatch Logs. Si cette autorisation n'est pas incluse, la

journalisation continue sera désactivée. De plus, pour configurer le chiffrement des CloudWatch journaux, suivez les instructions de la section [Chiffrer les données des CloudWatch journaux dans les journaux à l'aide AWS Key Management Service](#) du guide de l'utilisateur Amazon CloudWatch Logs.

Pour plus d'informations sur la création de configurations de sécurité, veuillez consulter [Gestion des configurations de sécurité sur le AWS Glue console](#).

 Note

Des frais supplémentaires peuvent vous être facturés lorsque vous activez la journalisation et que des événements de CloudWatch journalisation supplémentaires sont créés. Pour plus d'informations, consultez les [CloudWatch tarifs Amazon](#).

Afficher les journaux des AWS Glue offres d'emploi

Vous pouvez consulter les journaux en temps réel à l'aide de la AWS Glue console ou de la CloudWatch console Amazon.

Pour consulter les journaux en temps réel à l'aide du tableau de bord de AWS Glue la console

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le volet de navigation, sélectionnez Tâches.
3. Ajouter ou démarrer une tâche existante. Choisissez Action, Exécuter la tâche.

Lorsque vous démarrez l'exécution d'une tâche, vous accédez à une page qui contient des informations sur la tâche en cours d'exécution :

- L'onglet Journaux affiche les journaux des applications agrégés plus anciens.
 - L'onglet Logs affiche une barre de progression en temps réel lorsque le job est en cours d'exécution avec `glueContext` initialisé.
 - L'onglet Logs contient également les journaux des pilotes, qui capturent les journaux des pilotes Apache Spark en temps réel, et les journaux des applications à partir du script enregistré à l'aide de l'enregistreur d' AWS Glue applications lorsque le job est en cours d'exécution.
4. Pour les anciennes tâches, vous pouvez également afficher les journaux en temps réel sous la vue Job History (Historique des tâches) en choisissant Journaux. Cette action vous amène à la

CloudWatch console qui affiche tous les flux de log du pilote Spark, de l'exécuteur et de la barre de progression relatifs à cette tâche exécutée.

Pour consulter les journaux en temps réel à l'aide du tableau de bord de CloudWatch la console

1. Ouvrez la CloudWatch console à l'adresse <https://console.aws.amazon.com/cloudwatch/>.
2. Dans le volet de navigation, sélectionnez Journaux.
3. Choisissez le groupe de journaux `/aws-glue/jobs/error/`.
4. Dans la zone Filtre, collez l'ID d'exécution de la tâche

Vous pouvez afficher les journaux du pilote, les journaux du programme d'exécution et la barre de progression (si vous utilisez le Standard filter (Filtre standard)).

Surveillance avec AWS Glue Métriques d'observabilité

Note

AWS Glue Les métriques d'observabilité sont disponibles sur AWS Glue Versions 4.0 et ultérieures.

Utiliser AWS Glue Des indicateurs d'observabilité pour obtenir des informations sur ce qui se passe au sein de votre AWS Glue pour les tâches Apache Spark afin d'améliorer le triage et l'analyse des problèmes. Les métriques d'observabilité sont visualisées via des tableaux de bord Amazon CloudWatch et peuvent être utilisées pour analyser les causes racines des erreurs et pour diagnostiquer les goulots d'étranglement en matière de performance. Vous pouvez réduire le temps passé à déboguer les problèmes à l'échelle afin de vous concentrer sur leur résolution plus rapide et plus efficace.

AWS Glue L'observabilité fournit des Amazon CloudWatch métriques classées dans les quatre groupes suivants :

- Fiabilité (par exemple, classes d'erreurs) : identifier facilement les motifs d'échec les plus courants sur une plage de temps donnée que vous souhaitez remédier.
- Performance (par exemple, asymétrie) : identifier un goulot d'étranglement en matière de performance et appliquer des techniques de réglage. Par exemple, lorsque vos performances sont

dégradées en raison de l'asymétrie des tâches, vous pouvez activer l'Exécution adaptative des requêtes Spark et affiner le seuil de jointure asymétrique.

- Débit (c'est-à-dire le débit par source/récepteur) : surveiller les tendances en matière de lecture et d'écriture de données. Vous pouvez également configurer des Amazon CloudWatch alarmes en cas d'anomalie.
- Utilisation des ressources (c'est-à-dire utilisation du personnel, de la mémoire et du disque) : trouver de manière efficace les tâches dont l'utilisation des capacités est faible. Vous souhaitez peut-être activer AWS Glue auto-scaling pour ces tâches.

Démarrage avec AWS Glue Métriques d'observabilité

Note

Les nouvelles métriques sont activées par défaut dans AWS Glue Studio console.

Pour configurer les métriques d'observabilité dans AWS Glue Studio:

1. Connectez-vous au AWS Glue console et choisissez les tâches ETL dans le menu de la console.
2. Choisissez une tâche en cliquant sur le nom de la tâche dans la section Vos tâches.
3. Sélectionnez l'onglet Job details (Détails de la tâche).
4. Faites défiler l'écran vers le bas et choisissez Propriétés avancées, puis Metriques d'observabilité de la tâche.

obs-test Last modified on 10/10/2023, 2:04:44 PM [Try new UI](#) [Load JSON](#) [De](#)

Visual | Script | **Job details** | Runs | Data quality [New](#) | Schedules | Version Control

▼ Advanced properties

Script filename

Script path
S3 location of the script. Path must be in the form s3://bucket/prefix/path/. It must end with a slash (/) and not include any files.
 [View](#) [Browse S3](#)

Job metrics [Info](#)
☒ Enable the creation of CloudWatch metrics when this job runs.

Job observability metrics [Info](#)
☒ Enable the creation of additional observability CloudWatch metrics when this job runs.

Continuous logging [Info](#)
☒ Enable logs in CloudWatch.

Spark UI [Info](#)
☒ Enable using Spark UI for monitoring this job.

Serverless Spark UI [Info](#)
☒ Enable using Serverless Spark UI for monitoring this job.

Spark UI logs path
 [View](#) [Browse S3](#)

Maximum concurrency
Sets the maximum number of concurrent runs that are allowed for this job. An error is returned when this threshold is reached.

Temporary path
Working directory. Path must be in the form s3://bucket/prefix/path/. It must end with a slash (/) and not include any files.
 [View](#) [Browse S3](#)

Delay notification threshold (minutes) [Info](#)

Pour activer AWS Glue Mesures d'observabilité utilisant AWS CLI :

- Ajoutez à la carte `--default-arguments` la valeur clé suivante dans le fichier JSON d'entrée :

```
--enable-observability-metrics, true
```

Utilisation AWS Glue observabilité


Parce que le AWS Glue les métriques d'observabilité sont fournies via la Amazon CloudWatch console Amazon CloudWatch AWS CLI, le SDK ou l'API pour interroger les points de données des

métriques d'observabilité. Voir [Using Glue Observability pour surveiller l'utilisation des ressources afin de réduire les coûts](#). Voici un exemple de cas d'utilisation dans lequel utiliser AWS Glue métriques d'observabilité.

Utilisation AWS Glue observabilité dans la console Amazon CloudWatch

Pour interroger et visualiser les métriques dans la Amazon CloudWatch console, procédez comme suit :

1. Ouvrez la Amazon CloudWatch console et choisissez Toutes les mesures.
2. Sous espaces de noms personnalisés, choisissez AWS Glue.
3. Choisissez les métriques d'observabilité de la tâche, les métriques d'observabilité par source ou les métriques d'observabilité par récepteur.
4. Recherchez le nom de la métrique, le nom de la tâche, l'ID d'exécution de la tâche spécifiques, puis sélectionnez-les.
5. Sous l'onglet Métriques sous forme de graphique, configurez vos statistiques, périodes et autres options préférées.



Pour interroger une métrique d'observabilité à l'aide AWS CLI de :

1. Créez un fichier JSON de définition de métrique et remplacez `your-Glue-job-name` et `your-Glue-job-run-id` par les vôtres.

```
$ cat multiplequeries.json
[
  {
    "Id": "avgWorkerUtil_0",
```

```

    "MetricStat": {
      "Metric": {
        "Namespace": "Glue",
        "MetricName": "glue.driver.workerUtilization",
        "Dimensions": [
          {
            "Name": "JobName",
            "Value": "<your-Glue-job-name-A>"
          },
          {
            "Name": "JobRunId",
            "Value": "<your-Glue-job-run-id-A>"
          },
          {
            "Name": "Type",
            "Value": "gauge"
          },
          {
            "Name": "ObservabilityGroup",
            "Value": "resource_utilization"
          }
        ]
      },
      "Period": 1800,
      "Stat": "Minimum",
      "Unit": "None"
    }
  },
  {
    "Id": "avgWorkerUtil_1",
    "MetricStat": {
      "Metric": {
        "Namespace": "Glue",
        "MetricName": "glue.driver.workerUtilization",
        "Dimensions": [
          {
            "Name": "JobName",
            "Value": "<your-Glue-job-name-B>"
          },
          {
            "Name": "JobRunId",
            "Value": "<your-Glue-job-run-id-B>"
          },
          {

```

```

        "Name": "Type",
        "Value": "gauge"
      },
      {
        "Name": "ObservabilityGroup",
        "Value": "resource_utilization"
      }
    ]
  },
  "Period": 1800,
  "Stat": "Minimum",
  "Unit": "None"
}
]

```

2. Exécutez la commande `get-metric-data` :

```

$ aws cloudwatch get-metric-data --metric-data-queries file: //multiplequeries.json \
\
  --start-time '2023-10-28T18: 20' \
  --end-time '2023-10-28T19: 10' \
  --region us-east-1
{
  "MetricDataResults": [
    {
      "Id": "avgWorkerUtil_0",
      "Label": "<your-label-for-A>",
      "Timestamps": [
        "2023-10-28T18:20:00+00:00"
      ],
      "Values": [
        0.06718750000000001
      ],
      "StatusCode": "Complete"
    },
    {
      "Id": "avgWorkerUtil_1",
      "Label": "<your-label-for-B>",
      "Timestamps": [
        "2023-10-28T18:50:00+00:00"
      ],

```

```
        "Values": [  
            0.5959183673469387  
        ],  
        "StatusCode": "Complete"  
    }  
],  
"Messages": []  
}
```

Métriques d'observabilité

AWS Glue L'observabilité établit des profils et envoie les mesures suivantes Amazon CloudWatch toutes les 30 secondes. Certaines de ces mesures peuvent être visibles dans le AWS Glue Studio Page de surveillance des exécutions de tâches.

Métrique	Description	Catégorie
glue.driver.skewness.stage	Catégorie de métrique : job_performance Asymétrie de l'exécution des étapes Spark : cette métrique capture l'asymétrie d'exécution, qui peut être causée par une asymétrie des données d'entrée ou par une transformation (par exemple, une jointure asymétrique). Les valeurs de cette métrique se situent dans l'intervalle [0, infini], où 0 signifie que le rapport entre le temps d'exécution maximum et médian des tâches, parmi toutes les tâches de l'étape, est inférieur à un certain facteur d'asymétrie d'étape.	job_performance

Métrique	Description	Catégorie
	Le facteur d'asymétrie d'étape par défaut est « 5 » et il peut être modifié via la configuration Spark : <code>spark.metrics.conf.driver.source.glue.jobPerformance.skewnessFactor</code> Une valeur d'asymétrie d'étape de 1 signifie que le rapport est le double du facteur d'asymétrie d'étape. La valeur de l'asymétrie de la scène est mise à jour toutes les 30 secondes pour refléter l'asymétrie actuelle. La valeur à la fin de l'étape reflète l'asymétrie de l'étape finale. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (job_performance) Statistiques valides : moyenne, maximum, minimum, centile Unité : nombre	

Métrique	Description	Catégorie
glue.driver.skewness.job	Catégorie de métrique : job_performance L'asymétrie de la tâche est la moyenne pondérée de l'asymétrie des étapes de la tâche. La moyenne pondérée donne plus de poids aux étapes dont l'exécution prend plus de temps. Cela permet d'éviter le cas particulier où une étape très asymétrique s'exécute en réalité pendant un temps très court par rapport aux autres étapes (et donc son asymétrie n'est pas significative pour la performance globale de la tâche et ne mérite pas l'effort de tenter de corriger son asymétrie). Cette métrique est mise à jour à la fin de chaque étape. La dernière valeur reflète donc l'asymétrie globale réelle de la tâche. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (job_performance)	job_performance

Métrique	Description	Catégorie
	Statistiques valides : moyenne, maximum, minimum, centile Unité : nombre	
glue.succeed.ALL	Catégorie de métrique : erreur Nombre total d'exécutions de tâches réussies, pour compléter le tableau des catégories d'échec Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l'JobRun identifiant ou ALL), le type (nombre) et ObservabilityGroup (erreur) Statistiques valides : SUM Unité : nombre	error

Métrique	Description	Catégorie
glue.error.ALL	Catégorie de métrique : erreur Nombre total d'erreurs d'exécution de tâche, pour compléter le tableau des catégories d'échec Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l'JobRun identifiant ou ALL), le type (nombre) et ObservabilityGroup (erreur) Statistiques valides : SUM Unité : nombre	error

Métrique	Description	Catégorie
glue.error.[error category]	Catégorie de métrique : erreur Il s'agit en fait d'un ensemble de métriques, qui sont mises à jour uniquement lorsqu'une exécution de tâche échoue. La catégorisation des erreurs facilite le triage et le débogage. Lorsqu'une exécution de tâche échoue, l'erreur à l'origine de l'échec est catégorisée et la métrique de la catégorie d'erreur correspondante est définie à 1. Cela permet d'effectuer une analyse des défaillances au fil du temps, ainsi qu'une analyse des erreurs sur l'ensemble des tâches afin d'identifier les catégories de défaillances les plus courantes et de commencer à y remédier. AWS Glue comporte 28 catégories d'erreurs, dont les catégories OUT_OF_MEMORY (pilote et exécuteur), PERMISSION, SYNTAX et THROTTLING. Les catégories d'erreur incluent également les catégories d'erreur COMPILATION, LAUNCH et TIMEOUT. Dimensions valides : JobName (nom du AWS	error

Métrique	Description	Catégorie
	Glue Job), JobRunId (l' JobRun identifiant ou ALL), le type (nombre) et ObservabilityGroup (erreur) Statistiques valides : SUM Unité : nombre	
glue.driver.workerUtilization	Catégorie de métrique : resource_utilization Le pourcentage des travailleurs affectés qui sont réellement utilisés. Si ce n'est pas bon, l'autoscaling peut vous aider. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne, maximum, minimum, centile Unité : pourcentage	resource_utilization

Métrique	Description	Catégorie
glue.driver.memory.heap.[available used]	Catégorie de métrique : resource_utilization Tas disponible/utilisé par le pilote pendant l'exécution de la tâche. Cela aide à comprendre les tendances d'utilisation de la mémoire, particulièrement au fil du temps, ce qui peut contribuer à éviter des échecs potentiels, en plus de déboguer les échecs liés à la mémoire. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : octets	resource_utilization

Métrique	Description	Catégorie
glue.driver.memory.heap.used.percentage	Catégorie de métrique : resource_utilization Tas utilisé (%) par le pilote pendant l'exécution de la tâche. Cela aide à comprendre les tendances d'utilisation de la mémoire, particulièrement au fil du temps, ce qui peut contribuer à éviter des échecs potentiels, en plus de déboguer les échecs liés à la mémoire. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : pourcentage	resource_utilization

Métrique	Description	Catégorie
glue.driver.memory.non-heap. [available used]	Catégorie de métrique : resource_utilization Mémoire hors tas disponible/ utilisée par le pilote pendant l'exécution de la tâche. Cela aide à comprendre les tendances d'utilisation de la mémoire, particuli èrement au fil du temps, ce qui peut contribuer à éviter des échecs potentiels, en plus de débuguer les échecs liés à la mémoire. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource _utilization) Statistiques valides : moyenne Unité : octets	resource_utilization

Métrique	Description	Catégorie
glue.driver.memory.non-heap .used.percentage	Catégorie de métrique : resource_utilization Mémoire hors tas utilisée (%) par le pilote pendant l'exécution de la tâche. Cela aide à comprendre les tendances d'utilisation de la mémoire, particulièrement au fil du temps, ce qui peut contribuer à éviter des échecs potentiels, en plus de déboguer les échecs liés à la mémoire. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : pourcentage	resource_utilization

Métrique	Description	Catégorie
glue.driver.memory.total.[available used]	Catégorie de métrique : resource_utilization Mémoire totale disponible/ utilisée par le pilote pendant l'exécution de la tâche. Cela aide à comprendre les tendances d'utilisation de la mémoire, particulièrement au fil du temps, ce qui peut contribuer à éviter des échecs potentiels, en plus de déboguer les échecs liés à la mémoire. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : octets	resource_utilization

Métrique	Description	Catégorie
glue.driver.memory.total.used.percentage	Catégorie de métrique : resource_utilization Mémoire totale utilisée (%) par le pilote pendant l'exécution de la tâche. Cela aide à comprendre les tendances d'utilisation de la mémoire, particulièrement au fil du temps, ce qui peut contribuer à éviter des échecs potentiels, en plus de déboguer les échecs liés à la mémoire. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : pourcentage	resource_utilization

Métrique	Description	Catégorie
glue.ALL.memory.heap.[available used]	Catégorie de métrique : resource_utilization Tas disponible/utilisé par les exécuteurs. ALL signifie tous les exécuteurs. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : octets	resource_utilization
glue.ALL.memory.heap.used.pourcentage	Catégorie de métrique : resource_utilization Tas utilisé (%) par les exécuteurs. ALL signifie tous les exécuteurs. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : pourcentage	resource_utilization

Métrique	Description	Catégorie
glue.ALL.memory.non-heap.[available used]	Catégorie de métrique : resource_utilization Mémoire hors tas disponible/utilisée par les exécuteurs. ALL signifie tous les exécuteurs. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : octets	resource_utilization
glue.ALL.memory.non-heap.used.percentage	Catégorie de métrique : resource_utilization Mémoire hors tas /utilisée (%) par les exécuteurs. ALL signifie tous les exécuteurs. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : pourcentage	resource_utilization

Métrique	Description	Catégorie
glue.ALL.memory.total.[available used]	Catégorie de métrique : resource_utilization Mémoire totale disponible/ utilisée par les exécuteurs. ALL signifie tous les exécuteurs. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : octets	resource_utilization
glue.ALL.memory.total.used.percentage	Catégorie de métrique : resource_utilization Mémoire totale utilisée (%) par les exécuteurs. ALL signifie tous les exécuteurs. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : pourcentage	resource_utilization

Métrique	Description	Catégorie
glue.driver.disk.[available_GB used_GB]	Catégorie de métrique : resource_utilization Espace disque disponible/ utilisé par le pilote pendant l'exécution de la tâche. Cela aide à comprendre les tendances d'utilisation du disque, particulièrement au fil du temps, ce qui peut contribuer à éviter des échecs potentiels, en plus de déboguer les échecs liés à un espace disque insuffisant. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : gigaoctets	resource_utilization

Métrique	Description	Catégorie
glue.driver.disk.used.percentage]	Catégorie de métrique : resource_utilization Espace disque disponible/ utilisé par le pilote pendant l'exécution de la tâche. Cela aide à comprendre les tendances d'utilisation du disque, particulièrement au fil du temps, ce qui peut contribuer à éviter des échecs potentiels, en plus de débuguer les échecs liés à un espace disque insuffisant. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource _utilization) Statistiques valides : moyenne Unité : pourcentage	resource_utilization

Métrique	Description	Catégorie
glue.ALL.disk.[available_GB used_GB]	Catégorie de métrique : resource_utilization Espace disque disponible/ utilisé par les exécuteurs. ALL signifie tous les exécuteurs. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : gigaoctets	resource_utilization
glue.ALL.disk.used.percenta ge	Catégorie de métrique : resource_utilization Espace disque available/used/ used (%) des exécuteurs. ALL signifie tous les exécuteurs. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge) et ObservabilityGroup (resource_utilization) Statistiques valides : moyenne Unité : pourcentage	resource_utilization

Métrique	Description	Catégorie
glue.driver.bytesRead	Catégorie de métrique : débit Nombre d'octets lus par source d'entrée lors de cette exécution de tâche, ainsi que pour TOUTES les sources. Cela aide à comprendre le volume de données et ses variations au fil du temps, ce qui est utile pour résoudre des problèmes tels que l'asymétrie des données. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun identifiant ou ALL), le type (jauge), ObservabilityGroup (resource_utilization) et la source (emplacement des données source) Statistiques valides : moyenne Unité : octets	débit

Métrique	Description	Catégorie
glue.driver.[recordsRead filesRead]	Catégorie de métrique : débit Nombre d'enregistrements/ fichiers lus par source d'entrée lors de cette exécution de tâche, ainsi que pour TOUTES les sources. Cela aide à comprendre le volume de données et ses variations au fil du temps, ce qui est utile pour résoudre des problèmes tels que l'asymétrie des données. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun identifiant ou ALL), le type (jauge), ObservabilityGroup (resource_utilization) et la source (emplacement des données source) Statistiques valides : moyenne Unité : nombre	débit

Métrique	Description	Catégorie
glue.driver.partitionsRead	Catégorie de métrique : débit Nombre de partitions lues par source d'entrée Amazon S3 dans cette exécution de tâche, ainsi que pour TOUTES les sources. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun identifiant ou ALL), le type (jauge), ObservabilityGroup (resource_utilization) et la source (emplacement des données source) Statistiques valides : moyenne Unité : nombre	débit

Métrique	Description	Catégorie
glue.driver.bytesWritten	Catégorie de métrique : débit Nombre d'octets écrits par récepteur de sortie dans cette exécution de tâche, ainsi que pour TOUS les récepteurs. Cela aide à comprendre le volume de données et son évolution au fil du temps, ce qui est utile pour résoudre des problèmes tels que l'asymétrie de traitement. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge), ObservabilityGroup (resource _utilization) et Sink (emplacement des données du puits) Statistiques valides : moyenne Unité : octets	débit

Métrique	Description	Catégorie
glue.driver.[recordsWritten filesWritten]	Catégorie de métrique : débit Nombre d'enregistrements/ fichiers écrits par récepteur de sortie dans cette exécution de tâche, ainsi que pour TOUS les récepteurs. Cela aide à comprendre le volume de données et son évolution au fil du temps, ce qui est utile pour résoudre des problèmes tels que l'asymétrie de traitement. Dimensions valides : JobName (nom du AWS Glue Job), JobRunId (l' JobRun ID ou ALL), Type (gauge), ObservabilityGroup (resource _utilization) et Sink (emplacement des données du puits) Statistiques valides : moyenne Unité : nombre	débit

Catégories d'erreur

Catégories d'erreur	Description
COMPILATION_ERROR	Des erreurs surviennent lors de la compilation du code Scala.
CONNECTION_ERROR	Des erreurs surviennent lors de la connexion à un service/remote host/database service, etc.

Catégories d'erreur	Description
DISK_NO_SPACE_ERROR	Des erreurs surviennent lorsqu'il n'y a plus d'espace disponible sur le disque du pilote/de l'exécuteur.
OUT_OF_MEMORY_ERROR	Des erreurs surviennent lorsqu'il n'y a plus d'espace disponible dans la mémoire du pilote/de l'exécuteur.
IMPORT_ERROR	Des erreurs surviennent lors de l'importation de dépendances.
INVALID_ARGUMENT_ERROR	Des erreurs surviennent lorsque les arguments d'entrée sont invalides/illégaux.
PERMISSION_ERROR	Les erreurs surviennent en cas d'absence d'autorisation d'accès au service, aux données, etc.
RESOURCE_NOT_FOUND_ERROR	Des erreurs surviennent lorsque les données, l'emplacement, etc. ne sont pas disponibles.
QUERY_ERROR	Des erreurs surviennent lors de l'exécution de requêtes SQL dans Spark.
SYNTAX_ERROR	Des erreurs surviennent lorsqu'il y a une erreur de syntaxe dans le script.
THROTTLING_ERROR	Des erreurs surviennent lorsqu'une limite de simultanéité de service est atteinte ou qu'une limitation de quota de service est dépassée.
DATA_LAKE_FRAMEWORK_ERROR	Les erreurs proviennent de AWS Glue framework de lac de données supporté en mode natif comme Hudi, Iceberg, etc.
UNSUPPORTED_OPERATION_ERROR	Des erreurs surviennent lors d'une opération non prise en charge.

Catégories d'erreur	Description
RESOURCES_ALREADY_EXISTS_ERROR	Des erreurs surviennent lorsqu'une ressource à créer ou à ajouter existe déjà.
GLUE_INTERNAL_SERVICE_ERROR	Des erreurs surviennent lorsqu'il existe un AWS Glue problème de service interne.
GLUE_OPERATION_TIMEOUT_ERROR	Des erreurs surviennent lorsqu'un AWS Glue l'opération est un délai d'expiration.
GLUE_VALIDATION_ERROR	Des erreurs surviennent lorsqu'une valeur requise n'a pas pu être validée pour AWS Glue travail.
GLUE_JOB_BOOKMARK_VERSION_MISMATCH_ERROR	Des erreurs surviennent lorsqu'une même tâche s'exécute dans le même compartiment source et écrit simultanément vers la même destination ou une destination différente (simultanéité >1)
LAUNCH_ERROR	Des erreurs se produisent au cours de AWS Glue phase de lancement du projet.
DYNAMODB_ERROR	Les erreurs génériques proviennent du Amazon DynamoDB service.
GLUE_ERROR	Les erreurs génériques proviennent de AWS Glue service.
LAKEFORMATION_ERROR	Les erreurs génériques proviennent du AWS Lake Formation service.
REDSHIFT_ERROR	Les erreurs génériques proviennent du Amazon Redshift service.
S3_ERROR	Les erreurs génériques proviennent du service Amazon S3.

Catégories d'erreur	Description
SYSTEM_EXIT_ERROR	Erreur de sortie du système générique.
TIMEOUT_ERROR	Des erreurs génériques surviennent lorsque la tâche échoue en raison du dépassement du délai d'exécution de l'opération.
UNCLASSIFIED_SPARK_ERROR	Les erreurs génériques proviennent de Spark.
UNCLASSIFIED_ERROR	Catégorie d'erreur par défaut.

Limites

Note

`glueContext` doit être initialisé pour publier les métriques.

Dans la dimension source, la valeur est soit le chemin Amazon S3, soit le nom de la table, selon le type de source. En outre, si la source est JDBC et que l'option de requête est utilisée, la chaîne de requête est définie dans la dimension source. Si la valeur est supérieure à 500 caractères, elle est réduite à 500 caractères maximum. Les limites de la valeur sont les suivantes :

- Les caractères non ASCII seront supprimés.
- Si le nom de la source ne contient aucun caractère ASCII, il est converti en <non-ASCII input>.

Limites et considérations relatives aux métriques de débit

- `DataFrame` et `DataFrame` basés `DynamicFrame` (par exemple JDBC, lecture depuis parquet sur Amazon S3) sont pris en charge, mais les fichiers basés sur `RDD DynamicFrame` (par exemple, lecture de csv, de json sur Amazon S3, etc.) ne sont pas pris en charge. Techniquement, toutes les lectures et écritures visibles sur l'interface utilisateur de Spark sont prises en charge.
- La métrique `recordsRead` sera émise si la source de données est une table de catalogue et que le format est JSON, CSV, texte ou Iceberg.

- Les métriques `glue.driver.throughput.recordsWritten`, `glue.driver.throughput.bytesWritten` et `glue.driver.throughput.filesWritten` ne sont pas disponibles dans les tables JDBC et Iceberg.
- Les métriques peuvent être retardées. Si le travail se termine dans environ une minute, il se peut qu'il n'y ait aucune métrique de débit dans Amazon CloudWatch Metrics.

Surveillance et débogage des tâches

Vous pouvez collecter des statistiques sur AWS Glue emplois et visualisez-les sur le AWS Glue et des CloudWatch consoles Amazon pour identifier et résoudre les problèmes. Profilage de votre AWS Glue les tâches nécessitent les étapes suivantes :

1. Activation des métriques :
 - a. Activer l'option de métriques de tâche dans la définition de la tâche. Vous pouvez activer le profilage dans AWS Glue console ou en tant que paramètre de la tâche. Pour plus d'informations, consultez [Définition des propriétés des tâches Spark](#) ou [Utilisation des paramètres des tâches dans les tâches AWS Glue](#).
 - b. Activer la gem AWS Glue Option de métriques d'observabilité dans la définition de la tâche. Vous pouvez activer l'observabilité dans AWS Glue console ou en tant que paramètre de la tâche. Pour plus d'informations, voir [Surveillance avec AWS Glue Métriques d'observabilité](#).
2. Vérifiez que le script de la tâche initialise un `GlueContext`. Par exemple, l'extrait de script suivant initialise un `GlueContext` et indique où le code profilé est placé dans le script. Ce format général est utilisé dans les scénarios de débogage suivants.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
import time

## @params: [JOB_NAME]
args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
```

```
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args['JOB_NAME'], args)

...
...
code-to-profile
...
...

job.commit()
```

3. Exécutez la tâche.
4. Visualisez les métriques :
 - a. Visualisez les indicateurs relatifs aux tâches sur le AWS Glue console et identifiez les métriques anormales pour le pilote ou un exécuteur.
 - b. Consultez les indicateurs d'observabilité sur la page de surveillance des tâches, sur la page des détails de l'exécution des tâches ou sur Amazon CloudWatch. Pour de plus amples informations, veuillez consulter [Surveillance avec AWS Glue Métriques d'observabilité](#).
5. Précisez la cause première à l'aide de la métrique identifiée.
6. Confirmez éventuellement la cause première à l'aide du flux de journaux du pilote identifié ou du programme d'exécution.

Cas d'utilisation pour AWS Glue métriques d'observabilité

- [Débogage des exceptions OOM et des anomalies de tâches](#)
- [Débogage d'étapes exigeantes et de tâches de ralentissement](#)
- [Surveillance de la progression des tâches multiples](#)
- [Surveillance de la planification des capacités de DPU](#)
- [En utilisant AWS Glue Observabilité pour surveiller l'utilisation des ressources afin de réduire les coûts](#)

Débogage des exceptions OOM et des anomalies de tâches

Vous pouvez déboguer les exceptions out-of-memory (OOM) et les anomalies de tâches dans AWS Glue. Les sections suivantes décrivent les scénarios de débogage des out-of-memory exceptions du pilote Apache Spark ou d'un exécuteur Spark.

- [Débogage d'un pilote d'exception OOM](#)
- [Débogage d'un programme d'exécution d'exception OOM](#)

Débogage d'un pilote d'exception OOM

Dans ce scénario, une tâche Spark lit un grand nombre de petits fichiers d'Amazon Simple Storage Service (Amazon S3). Il convertit les fichiers au format Apache Parquet, puis les écrit dans Amazon S3. Le pilote Spark manque de mémoire. Les données d'entrées Amazon S3 comptent plus d'un million de fichiers dans différentes partitions Amazon S3.

Le code profilé est le suivant :

```
data = spark.read.format("json").option("inferSchema", False).load("s3://input_path")
data.write.format("parquet").save(output_path)
```

Voir les métriques profilées sur la console AWS Glue

Le graphique suivant illustre l'utilisation de la mémoire sous forme de pourcentage pour le pilote et les programmes d'exécution. Cette utilisation est déterminée par un point de données qui est moyenné sur les valeurs rapportées au cours de la dernière minute. Vous pouvez voir dans le profil de la mémoire de la tâche que le [pilote de la mémoire](#) dépasse le seuil de sécurité de 50 % d'utilisation rapidement. D'autre part, l' [utilisation moyenne de la mémoire](#) sur l'ensemble des programmes d'exécution reste inférieure à 4 %. Ceci montre clairement l'anomalie de l'exécution du pilote dans cette tâche Spark.



L'exécution de la tâche échoue rapidement et l'erreur suivante apparaît dans l'onglet Historique du AWS Glue console : échec de la commande avec le code de sortie 1. Cette chaîne d'erreur signifie que la tâche a échoué en raison d'une erreur systémique ; dans le cas présent, le pilote manque de mémoire.

☒ e2e-metrics
python
s3://aws-glue-scripts-6569...
7 June 2018 7:37 PM UTC-7
Disable

History

Details

Script

Metrics

Run ID

Retry attempt

Run status

Error

Logs

Error logs

Execution time

Timeout

Delay

Triggered by

Start time

jr_651bfc34...

-

Failed

❗ ...

Logs

Error logs

2 mins

2880 mins

7 June 2018

jr_5731b225...

-

Failed

Command failed with exit code 1

ins

2880 mins

7 June 2018

Sur la console, cliquez sur le lien Journaux d'erreurs dans l'onglet Historique pour confirmer les conclusions relatives au pilote OOM contenues dans les CloudWatch journaux. Recherchez « **Error** » dans les journaux d'erreurs de la tâche pour vérifier que c'est bien à cause d'une exception OOM que la tâche a échoué :

```
# java.lang.OutOfMemoryError: Java heap space
```

```
# -XX:OnOutOfMemoryError="kill -9 %p"  
# Executing /bin/sh -c "kill -9 12039"...
```

Dans l'onglet Historique de la tâche, choisissez Journaux. Vous pouvez trouver la trace suivante de l'exécution du pilote dans les CloudWatch journaux au début de la tâche. Le pilote Spark essaie de répertorier tous les fichiers dans tous les répertoires, il génère un `InMemoryFileIndex` et lance une tâche par fichier. Par conséquent, le pilote Spark doit conserver une grande quantité d'état en mémoire pour suivre toutes les tâches. Il met en cache une liste complète comprenant un grand nombre de fichiers pour l'index en mémoire, ce qui se traduit par un pilote OOM.

Corriger le traitement de fichiers multiples grâce au regroupement


Vous pouvez corriger le traitement de plusieurs fichiers en utilisant la fonction de regroupement dans AWS Glue. Le regroupement est automatiquement activé lorsque vous utilisez des cadres dynamiques et lorsque le jeu de données en entrée contient un grand nombre de fichiers (plus de 50 000). Le regroupement vous permet de fusionner plusieurs fichiers en un groupe, et il permet à une tâche de traiter l'ensemble du groupe plutôt qu'un seul fichier. Par conséquent, le pilote Spark stocke nettement moins d'état en mémoire pour suivre moins de tâches. Pour plus d'informations sur l'activation manuelle du regroupement pour votre ensemble de données, consultez [Lecture des fichiers en entrée dans des groupes de plus grande taille](#).

Pour vérifier le profil de mémoire du AWS Glue job, profilez le code suivant avec le regroupement activé :


```
df = glueContext.create_dynamic_frame_from_options("s3", {'paths': ["s3://input_path"],  
  "recurse":True, 'groupFiles': 'inPartition'}, format="json")  
datasink = glueContext.write_dynamic_frame.from_options(frame = df, connection_type  
  = "s3", connection_options = {"path": output_path}, format = "parquet",  
  transformation_ctx = "datasink")
```

Vous pouvez surveiller le profil de mémoire et le mouvement des données ETL dans AWS Glue profil de poste.

Le pilote fonctionne en dessous du seuil de 50 % d'utilisation de la mémoire pendant toute la durée du AWS Glue travail. Les programmes d'exécution diffusent des données depuis Amazon S3, les traitent et les écrivent dans Amazon S3. Par conséquent, ils consomment moins de 5 % de mémoire, quel que soit le moment.



Le profil de déplacement des données ci-dessous montre le nombre total d'octets d'Amazon S3 lus et écrits au cours de la dernière minute par tous les programmes d'exécution à mesure que la tâche progresse. Les deux suivent un modèle similaire car les données sont diffusées sur tous les programmes d'exécution. La tâche finit de traiter le million de fichiers en moins de trois heures.



Débogage d'un programme d'exécution d'exception OOM


Dans ce scénario, vous pouvez apprendre à déboguer des exceptions OOM pouvant se produire dans les programmes d'exécution d'Apache Spark. Le code suivant utilise le lecteur MySQL Spark pour lire une grande table d'environ 34 millions de lignes dans une tramedonnées Spark. Il l'écrit

ensuite sur Amazon S3 au format Parquet. Vous pouvez fournir les propriétés de connexion et utiliser les configurations Spark par défaut pour lire la table.


```
val connectionProperties = new Properties()
connectionProperties.put("user", user)
connectionProperties.put("password", password)
connectionProperties.put("Driver", "com.mysql.jdbc.Driver")
val sparkSession = glueContext.sparkSession
val dfSpark = sparkSession.read.jdbc(url, tableName, connectionProperties)
dfSpark.write.format("parquet").save(output_path)
```

Visualisez les métriques profilées sur le AWS Glue console

Si la pente du graphique d'utilisation de la mémoire est positive et dépasse 50 %, si la tâche échoue avant l'émission de la métrique suivante, l'épuisement de la mémoire peut en être à l'origine. Le graphique suivant montre qu'en une minute d'exécution, l'[utilisation moyenne de la mémoire](#) sur tous les programmes d'exécution dépasse rapidement 50 %. L'utilisation peut atteindre 92 % et le conteneur qui exécute le programme d'exécution est arrêté par Apache Hadoop YARN.



Comme le montre le graphique suivant, un [programme d'exécution unique](#) s'exécute toujours jusqu'à ce que la tâche échoue. En effet, un nouveau programme d'exécution est lancé pour remplacer celui qui a été arrêté. Les lectures de la source de données JDBC ne sont pas parallélisées par défaut, car cela nécessiterait le partitionnement de la table sur une colonne et d'ouvrir plusieurs connexions. Par conséquent, seul un programme d'exécution lit dans la table complète de manière séquentielle.



Comme le montre le graphique suivant, Spark tente de lancer une nouvelle tâche quatre fois avant l'échec de la tâche. Vous pouvez voir le [profil de la mémoire](#) de trois programmes d'exécution. Chaque programme d'exécution utilise rapidement toute sa mémoire. La quatrième programme d'exécution manque de mémoire et la tâche échoue. Par conséquent, sa métrique n'est pas immédiatement reportée.



Vous pouvez confirmer à l'aide de la chaîne d'erreur figurant sur le AWS Glue console sur laquelle la tâche a échoué en raison d'exceptions OOM, comme indiqué dans l'image suivante.

History												Details	Script	Metrics
Showing: 1 - 15														
Run ID	Retry attempt	Run status	Error	Logs	Error logs	Execution time	Timeout	Delay	Triggered by	Start time	End time			
j_0a0e92805e7589a815204...	-	Failed	org.apache.spark.SparkException: Job aborted due to stage failure: Task 0 in stage 0.0 failed 4 times, most recent failure: Lost task 0.3 in stage 0.0 (TID 3, ip-10-1-2-90.ec2.intern...	ERROR	ERROR	4 mins	2000 mins	-	-	13 June 2018 9:32 AM UT...	13 June 2018 9:32 AM UT...			
j_4fc7c72723c5d5834e90c0d2f5...	-	Failed	org.apache.spark.SparkException: Job aborted due to stage failure: Task 0 in stage 0.0 failed 4 times, most recent failure: Lost task 0.3 in stage 0.0 (TID 3, ip-10-1-2-90.ec2.intern...	ERROR	ERROR	0 secs	2880 mins	-	-	13 June 2018 9:48 AM UT...	13 June 2018 9:50 AM UT...			
j_070a0e92805e7589a815204...	-	Succeeded	executor 45: Executor 45 finished (executor 4 exited caused by one of the running tasks) Reason: Container killed by YARN for exceeding memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting spark.yarn.executor.memoryOverhead.	-	-	2 mins	2880 mins	-	-	13 June 2018 9:32 AM UT...	13 June 2018 9:44 AM UT...			
j_04c857823082bfad919f18a2...	-	Succeeded	executor 45: Executor 45 finished (executor 4 exited caused by one of the running tasks) Reason: Container killed by YARN for exceeding memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting spark.yarn.executor.memoryOverhead.	-	-	2 mins	2880 mins	-	-	13 June 2018 9:32 AM UT...	13 June 2018 9:44 AM UT...			
j_7ad5d558b36bcd330b7745...	-	Failed	executor 45: Executor 45 finished (executor 4 exited caused by one of the running tasks) Reason: Container killed by YARN for exceeding memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting spark.yarn.executor.memoryOverhead.	-	-	1 hr, 8 mins	2880 mins	-	-	12 June 2018 5:15 PM UT...	12 June 2018 6:31 PM UT...			

Journal de sortie des tâches : pour confirmer la découverte d'une exception OOM de l'exécuteur, consultez les CloudWatch journaux. Lorsque vous recherchez **Error**, vous trouvez les quatre programme d'exécution arrêtés en à peu près le même temps que la fenêtre l'affiche sur le tableau de bord des métriques. Ils sont tous résiliés par YARN à mesure qu'ils excèdent les limites de mémoire.

Programme d'exécution 1

```
18/06/13 16:54:29 WARN YarnAllocator: Container killed by YARN for exceeding
memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting
spark.yarn.executor.memoryOverhead.
18/06/13 16:54:29 WARN YarnSchedulerBackend$YarnSchedulerEndpoint: Container killed
by YARN for exceeding memory limits. 5.5 GB of 5.5 GB physical memory used. Consider
boosting spark.yarn.executor.memoryOverhead.
18/06/13 16:54:29 ERROR YarnClusterScheduler: Lost executor 1 on
ip-10-1-2-175.ec2.internal: Container killed by YARN for exceeding
memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting
spark.yarn.executor.memoryOverhead.
18/06/13 16:54:29 WARN TaskSetManager: Lost task 0.0 in stage 0.0 (TID 0,
ip-10-1-2-175.ec2.internal, executor 1): ExecutorLostFailure (executor 1
exited caused by one of the running tasks) Reason: Container killed by YARN for
exceeding memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting
spark.yarn.executor.memoryOverhead.
```

Programme d'exécution 2

```
18/06/13 16:55:35 WARN YarnAllocator: Container killed by YARN for exceeding
memory limits. 5.8 GB of 5.5 GB physical memory used. Consider boosting
spark.yarn.executor.memoryOverhead.
18/06/13 16:55:35 WARN YarnSchedulerBackend$YarnSchedulerEndpoint: Container killed
by YARN for exceeding memory limits. 5.8 GB of 5.5 GB physical memory used. Consider
boosting spark.yarn.executor.memoryOverhead.
18/06/13 16:55:35 ERROR YarnClusterScheduler: Lost executor 2 on
ip-10-1-2-16.ec2.internal: Container killed by YARN for exceeding
memory limits. 5.8 GB of 5.5 GB physical memory used. Consider boosting
spark.yarn.executor.memoryOverhead.
18/06/13 16:55:35 WARN TaskSetManager: Lost task 0.1 in stage 0.0 (TID 1,
ip-10-1-2-16.ec2.internal, executor 2): ExecutorLostFailure (executor 2 exited
```

caused by one of the running tasks) Reason: Container killed by YARN for exceeding memory limits. 5.8 GB of 5.5 GB physical memory used. Consider boosting `spark.yarn.executor.memoryOverhead`.

Programme d'exécution 3

```
18/06/13 16:56:37 WARN YarnAllocator: Container killed by YARN for exceeding
memory limits. 5.8 GB of 5.5 GB physical memory used. Consider boosting
spark.yarn.executor.memoryOverhead.
18/06/13 16:56:37 WARN YarnSchedulerBackend$YarnSchedulerEndpoint: Container killed
by YARN for exceeding memory limits. 5.8 GB of 5.5 GB physical memory used. Consider
boosting spark.yarn.executor.memoryOverhead.
18/06/13 16:56:37 ERROR YarnClusterScheduler: Lost executor 3 on
ip-10-1-2-189.ec2.internal: Container killed by YARN for exceeding
memory limits. 5.8 GB of 5.5 GB physical memory used. Consider boosting
spark.yarn.executor.memoryOverhead.
18/06/13 16:56:37 WARN TaskSetManager: Lost task 0.2 in stage 0.0 (TID 2,
ip-10-1-2-189.ec2.internal, executor 3): ExecutorLostFailure (executor 3
exited caused by one of the running tasks) Reason: Container killed by YARN for
exceeding memory limits. 5.8 GB of 5.5 GB physical memory used. Consider boosting
spark.yarn.executor.memoryOverhead.
```

Programme d'exécution 4

```
18/06/13 16:57:18 WARN YarnAllocator: Container killed by YARN for exceeding
memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting
spark.yarn.executor.memoryOverhead.
18/06/13 16:57:18 WARN YarnSchedulerBackend$YarnSchedulerEndpoint: Container killed
by YARN for exceeding memory limits. 5.5 GB of 5.5 GB physical memory used. Consider
boosting spark.yarn.executor.memoryOverhead.
18/06/13 16:57:18 ERROR YarnClusterScheduler: Lost executor 4 on
ip-10-1-2-96.ec2.internal: Container killed by YARN for exceeding
memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting
spark.yarn.executor.memoryOverhead.
18/06/13 16:57:18 WARN TaskSetManager: Lost task 0.3 in stage 0.0 (TID 3,
ip-10-1-2-96.ec2.internal, executor 4): ExecutorLostFailure (executor 4 exited
caused by one of the running tasks) Reason: Container killed by YARN for
exceeding memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting
spark.yarn.executor.memoryOverhead.
```


Corrigez le paramètre de taille de récupération en utilisant AWS Glue cadres dynamiques

Le programme d'exécution est arrivé à court de mémoire lors de la lecture de la table JDBC, car la configuration par défaut de la taille d'extraction du JDBC de Spark est zéro. Cela signifie que le pilote JDBC sur le programme d'exécution Spark tente d'extraire les 34 millions de lignes de la base de données et de les mettre en cache, même si Spark diffuse les lignes une par une. Avec Spark, vous pouvez éviter ce scénario en définissant le paramètre de taille d'extraction par une valeur autre que zéro.

Vous pouvez également résoudre ce problème en utilisant AWS Glue cadres dynamiques à la place. Par défaut, les images dynamiques utilisent une taille d'extraction de 1 000 lignes, qui est généralement une valeur suffisante. Par conséquent, le programme d'exécution n'utilise pas plus de 7 % de la mémoire totale. Le AWS Glue la tâche se termine en moins de deux minutes avec un seul exécuteur. Lors de l'utilisation AWS Glue les cadres dynamiques sont l'approche recommandée, il est également possible de définir la taille de récupération à l'aide de la `fetchsize` propriété Apache Spark. Consultez le [guide de Spark SQL DataFrames et des ensembles de données](#).

```
val (url, database, tableName) = {
  ("jdbc_url", "db_name", "table_name")
}
val source = glueContext.getSource(format, sourceJson)
val df = source.getDynamicFrame
glueContext.write_dynamic_frame.from_options(frame = df, connection_type = "s3",
  connection_options = {"path": output_path}, format = "parquet", transformation_ctx =
  "datasink")
```

Métriques profilées normales : la mémoire de l'[exécuteur](#) avec AWS Glue les images dynamiques ne dépassent jamais le seuil de sécurité, comme le montre l'image suivante. Il diffuse dans les lignes depuis la base de données et met en cache 1 000 lignes seulement dans le pilote JDBC quel que soit le moment. Une exception de mémoire insuffisante ne se produit pas.



Débugage d'étapes exigeantes et de tâches de ralentissement

Vous pouvez utiliser ... AWS Glue profilage des tâches pour identifier les étapes exigeantes et les tâches plus lentes dans vos tâches d'extraction, de transformation et de chargement (ETL). Une tâche retardée prend beaucoup plus de temps que les autres tâches d'une étape d'un AWS Glue travail. Par conséquent, l'étape s'effectue plus lentement, ce qui retarde aussi la durée d'exécution totale de la tâche.

Fusion de petits fichiers d'entrée pour obtenir de plus grands fichiers de sortie

Une tâche de ralentissement a lieu lorsque la distribution du travail au sein des différentes tâches n'est pas uniforme, ou qu'une asymétrie de données entraîne un plus important traitement de données par une tâche.

Vous pouvez profiler le code suivant un modèle commun dans Apache Spark pour fusionner un grand nombre de petits fichiers en de plus grands fichiers de sortie. Pour cet exemple, l'ensemble de données d'entrée est de 32 Go de fichiers compressés Gzip JSON. L'ensemble de données de sortie a environ 190 Go de fichiers JSON décompressés.

Le code profilé est le suivant :


```
datasource0 = spark.read.format("json").load("s3://input_path")
df = datasource0.coalesce(1)
df.write.format("json").save(output_path)
```

Visualisez les métriques profilées sur AWS Glue console


Vous pouvez profiler votre tâche pour examiner quatre différents ensembles de métriques :

- Déplacement de données ETL
- Remaniement de données sur les programmes d'exécution
- Exécution d'une tâche
- Profil de mémoire


Déplacement des données ETL : Dans le profil du Déplacement des données ETL, les octets sont [lus](#) assez rapidement par tous les programmes d'exécution lors de la première étape qui se termine au cours des six premières minutes. Toutefois, la durée totale d'exécution de la tâche est d'environ une heure, et elle est principalement constituée des [écritures](#) de données.



Remaniement de données sur les programmes d'exécution : Le nombre d'octets [lus](#) et [écrits](#) au cours du remaniement montre également un pic avant la fin de l'étape 2, comme le montrent les métriques de l'Exécution de tâche et du Remaniement de données. Suite au remaniement des données de tous les programmes d'exploitation, toutes les lectures et les écritures proviennent uniquement du programme d'exécution n°3.




Exécution de tâche : Comme le montre le graphique ci-dessous, tous les autres programmes d'exécution sont inactifs et sont finalement abandonnés avant 10:09. A ce stade, le nombre total de programmes d'exécution diminue et il n'en reste qu'un. Ceci montre clairement que le programme d'exécution numéro 3 se compose de la tâche de ralentissement, dont la durée d'exécution est la plus longue, et contribue à la plus grande partie de la durée d'exécution de la tâche.



Profil de la mémoire : Après les deux premières étapes, seul [le programme d'exécution n°3](#) consomme activement de la mémoire pour traiter les données. Les autres programmes d'exécution

sont simplement inactifs ou ont été abandonnés peu de temps après la fin des deux premières étapes.




Corriger les programmes d'exécution en retard à l'aide du regroupement

Vous pouvez éviter de traîner les exécuteurs en utilisant la fonction de regroupement dans AWS Glue. Utilisez le regroupement pour répartir les données de manière uniforme sur tous les exécuteurs et fusionnez les fichiers en fichiers plus volumineux en utilisant tous les exécuteurs disponibles sur le cluster. Pour de plus amples informations, veuillez consulter [Lecture des fichiers en entrée dans des groupes de plus grande taille](#).

Pour vérifier les mouvements de données ETL dans AWS Glue job, profilez le code suivant avec le regroupement activé :

```
df = glueContext.create_dynamic_frame_from_options("s3", {'paths': ["s3://input_path"],
"recurse":True, 'groupFiles': 'inPartition'}, format="json")
datasink = glueContext.write_dynamic_frame.from_options(frame = df, connection_type =
"s3", connection_options = {"path": output_path}, format = "json", transformation_ctx
= "datasink4")
```

Déplacement de données ETL : Les écritures de données sont désormais diffusées en parallèle avec les lectures de données pendant toute la durée d'exécution de la tâche. Par conséquent, la tâche est réalisée en huit minutes, soit beaucoup plus rapidement qu'avant.




Remaniement des données sur les programmes d'exécution : Les données d'entrée ayant fusionné lors des lectures grâce à la fonction de regroupement, il n'y a pas de remaniement de données coûteux suite aux lectures de données.



Exécution de tâche : Les métriques d'exécution de tâche montrent que le nombre total de programmes d'exécution actifs s'exécutant et traitant des données reste relativement constant. Il n'y a pas de ralentissement dans la tâche. Tous les programmes d'exécution restent actifs et ne sont pas abandonnés tant que la tâche n'est pas terminée. Comme il n'existe pas de remaniement intermédiaire de données sur les programmes d'exécution, il n'y a qu'une seule étape dans la tâche.



Memory profile (Profil de la mémoire) : les métriques montrent la [consommation de mémoire active](#) par l'ensemble des programmes d'exécution, confirmant une nouvelle fois qu'il existe une activité sur l'ensemble des programmes d'exécution. Les données étant parallèlement envoyées et reçues, l'espace mémoire total de tous les programmes d'exécution est à peu près uniforme et bien au-dessous du seuil de sécurité pour tous les programmes d'exécution.



Surveillance de la progression des tâches multiples

Vous pouvez profiler plusieurs AWS Glue tâches ensemble et surveiller le flux de données entre elles. Il s'agit d'un modèle de flux de travail courant qui nécessite la surveillance de la progression de chaque tâche, du journal de traitement des données, du retraitement des données et des signets de tâche.

Rubriques

- [Code profilé](#)
- [Visualisez les métriques profilées sur AWS Glue console](#)
- [Corriger le traitement des fichiers](#)

Code profilé

Ce flux de travail comprend deux tâches : une tâche d'entrée et une tâche de sortie. La tâche d'entrée est planifiée pour s'exécuter toutes les 30 minutes au moyen d'un déclencheur périodique. La tâche de sortie est planifiée pour s'exécuter après chaque exécution réussie de la tâche d'entrée. Ces tâches planifiées sont contrôlées au moyen de déclencheurs de tâche.

Triggers A trigger starts a job when it fires.

Trigger name	Trigger type	Trigger status	Trigger parameters	Jobs to trigger
☐ e2e-bookmark-input	Schedule	ACTIVATED	Every 15 minutes	e2ebookmark-input
☐ e2e-bookmark-output	Job events	ACTIVATED	Job events: e2ebookmark-input	e2e-bookmark

Input job (Tâche d'entrée) : cette tâche lit les données à partir d'un emplacement Amazon Simple Storage Service (Amazon S3), les transforme à l'aide d'ApplyMapping et les écrit à un emplacement Amazon S3 intermédiaire. Le code suivant est le code profilé pour la tâche d'entrée :


```
datasource0 = glueContext.create_dynamic_frame.from_options(connection_type="s3",
  connection_options = {"paths": ["s3://input_path"],
    "useS3ListImplementation":True,"recurse":True}, format="json")
applymapping1 = ApplyMapping.apply(frame = datasource0, mappings = [map_spec])
datasink2 = glueContext.write_dynamic_frame.from_options(frame = applymapping1,
  connection_type = "s3", connection_options = {"path": staging_path, "compression":
    "gzip"}, format = "json")
```

Output job (Tâche de sortie) : cette tâche lit la sortie de la tâche d'entrée à partir de l'emplacement intermédiaire dans Amazon S3, les transforme à nouveau et les écrit dans une destination :

```
datasource0 = glueContext.create_dynamic_frame.from_options(connection_type="s3",
    connection_options = {"paths": [staging_path],
    "useS3ListImplementation":True,"recurse":True}, format="json")
applymapping1 = ApplyMapping.apply(frame = datasource0, mappings = [map_spec])
datasink2 = glueContext.write_dynamic_frame.from_options(frame = applymapping1,
    connection_type = "s3", connection_options = {"path": output_path}, format = "json")
```

Visualisez les métriques profilées sur AWS Glue console

Le tableau de bord suivant superpose la métrique d'octets Amazon S3 écrits de la tâche d'entrée sur la métrique d'octets Amazon S3 lus selon la même chronologie pour la tâche de sortie. La chronologie montre différentes exécutions de tâche des tâches d'entrée et de sortie. La tâche d'entrée (en rouge) démarre toutes les 30 minutes. La tâche de sortie (en marron) démarre lorsque la tâche d'entrée se termine, avec une simultanée max. de 1.



Dans cet exemple, les [signets de tâche](#) ne sont pas activés. Aucun contexte de transformation n'est utilisé pour activer les signets de tâche dans le code de script.

Historique de tâche : les tâches d'entrée et de sortie s'exécutent plusieurs fois, à partir de 12 h 00, comme le montre l'onglet Historique.

La tâche d'entrée sur AWS Glue la console ressemble à ceci :


History											
Details Script Metrics											
Run ID	Retry attempt	Run status	Error	Logs	Error logs	Execution time	Timeout	Delay	Triggered by	Start time	End time
j_0ce47b1a561051f06caae9e...	-	Succeeded		Logs		8 mins	2880 mins		e2e-bookmark-input	11 June 2018 2:30 PM UT...	11 June 2018 2:40 PM UT...
j_1b49ecdf73dd7614cca2f4274...	-	Succeeded		Logs		8 mins	2880 mins		e2e-bookmark-input	11 June 2018 2:00 PM UT...	11 June 2018 2:10 PM UT...
j_07e4d5350ce516d89086821e...	-	Succeeded		Logs		7 mins	2880 mins		e2e-bookmark-input	11 June 2018 1:30 PM UT...	11 June 2018 1:46 PM UT...
j_7b349097744ba2ab655fb61...	-	Succeeded		Logs		15 mins	2880 mins		e2e-bookmark-input	11 June 2018 1:00 PM UT...	11 June 2018 1:16 PM UT...

L'image suivante montre la tâche de sortie :

Run ID	Retry attempt	Run status	Error	Logs	Error logs	Execution time	Timeout	Delay	Triggered by	Start time	End time
f_d2e5ba78770743d373d8dd63...	-	Failed	Max conc...	Logs	Error logs	0 secs	2880 mins		e2e-bookmark-output	11 June 2018 2:11 PM UT...	
f_3242babab08a6c6bfc0b5df2e3...	-	Succeeded		Logs		27 mins	2880 mins		e2e-bookmark-output	11 June 2018 1:47 PM UT...	11 June 2018 2:15 PM UT...
f_c98cccb031be794a2b3a8047b...	-	Succeeded		Logs		24 mins	2880 mins		e2e-bookmark-output	11 June 2018 1:17 PM UT...	11 June 2018 1:43 PM UT...
f_0029a3c6f66c6395d59c9f965...	-	Succeeded		Logs		17 mins	2880 mins		e2e-bookmark-output	11 June 2018 12:41 PM U...	11 June 2018 12:59 PM U...

Première exécution de tâche : comme le montre le graphique Octets de données lues et écrites ci-dessous, les premières exécutions des tâches d'entrée et de sortie entre 12 h 00 et 12 h 30 montrent à peu près la même zone sous les courbes. Ces zones représentent les octets Amazon S3 écrits par la tâche d'entrée et les octets Amazon S3 lus par la tâche de sortie. Ces données sont également confirmées par le taux d'octets Amazon S3 écrits (additionnés sur 30 minutes, la fréquence du déclencheur de tâche pour la tâche d'entrée). Le point de données pour le ratio d'exécution de la tâche d'entrée qui a commencé à 12 h 00 est également 1.

Le graphique suivant montre le taux de flux de données pour toutes les exécutions de tâches :



Deuxième exécution de tâche : dans la deuxième exécution de tâche, il existe une différence claire entre le nombre d'octets lus par la tâche de sortie et le nombre d'octets écrits par la tâche d'entrée. (Comparez la zone sous la courbe des deux exécutions de tâche de la tâche de sortie ou comparez les zones de la deuxième exécution des tâches d'entrée et de sortie.) Le ratio entre le nombre d'octets lus et écrits montre que la tâche de sortie lit environ 2,5x les données écrites par la tâche d'entrée dans la seconde période de 30 minutes, de 12 h 30 à 13 h 00. C'est parce que la tâche

de sortie a retraité la sortie de la première exécution de la tâche d'entrée car les signets de tâche n'étaient pas activés. Un ratio supérieur à 1 indique qu'un backlog de données supplémentaire a été traité par la tâche de sortie.

Troisième exécution de tâche : la tâche d'entrée est assez cohérente quant au nombre d'octets écrits (voir la zone sous les courbes rouges). Toutefois, la troisième exécution de la tâche d'entrée a duré plus longtemps que prévu (voir la longue queue de la courbe rouge). Par conséquent, la troisième exécution de la tâche de sortie a démarré en retard. La troisième exécution de tâche n'a traité qu'une fraction des données cumulées à l'emplacement intermédiaire dans les 30 minutes restantes entre 13 h 00 et 13 h 30. Le taux de débit d'octets indique que seules 0,83 des données écrites ont été traitées par la troisième exécution de la tâche d'entrée (voir le ratio à 13 h 00).

Chevauchement des tâches d'entrée et de sortie : la quatrième exécution de la tâche d'entrée a démarré à 13 h 30 comme prévu, avant la fin de la troisième exécution de la tâche de sortie. Ces deux exécutions de tâche se chevauchent partiellement. Toutefois, la troisième exécution de la tâche de sortie ne capture que les fichiers répertoriés dans l'emplacement intermédiaire d'Amazon S3, lorsqu'elle a commencé vers 13:17. Cela comprend toutes les sorties de données de la première exécution de la tâche d'entrée. Le ratio réel à 13 h 30 est d'environ 2,75. La troisième exécution de la tâche de sortie a traité environ 2,75x de données écrites par la quatrième exécution de la tâche d'entrée, de 13 h 30 à 14 h 00.

Comme le montrent ces images, la tâche de sortie retraite des données de toutes les précédentes exécutions de la tâche d'entrée à partir de l'emplacement intermédiaire. Par conséquent, la quatrième exécution de la tâche de sortie est la plus longue et elle chevauche la totalité de la cinquième exécution de la tâche d'entrée.

Corriger le traitement des fichiers

Vous devez vous assurer que la tâche de sortie ne traite les fichiers qui n'ont pas été traités par de précédentes exécutions de la tâche de sortie. Pour ce faire, activez les signets de tâche et configurez le contexte de transformation dans la tâche de sortie de la façon suivante :


```
datasource0 = glueContext.create_dynamic_frame.from_options(connection_type="s3",
    connection_options = {"paths": [staging_path],
    "useS3ListImplementation":True,"recurse":True}, format="json", transformation_ctx =
    "bookmark_ctx")
```

Lorsque les signets de tâche sont activés, la tâche de sortie ne retraite pas les données dans l'emplacement intermédiaire pour toutes les précédentes exécutions de la tâche d'entrée. Dans


l'image suivante montrant les données lues et écrites, la zone sous la courbe marron est assez cohérente et similaire aux courbes rouges.



Le rapports du flux d'octets reste également proche de 1, car des données supplémentaires ne sont pas traitées.



Une exécution de la tâche de sortie démarre et capture les fichiers dans l'emplacement intermédiaire avant que la prochaine exécution de la tâche d'entrée ne commence à placer d'autres données dans l'emplacement intermédiaire. Tant que c'est le cas, elle ne traite que les fichiers capturés lors de la précédente exécution de tâche de sortie, et le ratio reste proche de 1.



Supposons que la tâche d'entrée dure plus longtemps que prévu et que, par conséquent, la tâche de sortie capture des fichiers dans l'emplacement intermédiaire à partir de deux exécutions de tâche d'entrée. Le ratio est supérieur à 1 pour cette exécution de tâche de sortie. Toutefois, les exécutions de tâches de sortie suivantes ne traitent aucun fichier déjà traité par les précédentes exécutions de la tâche de sortie.

Surveillance de la planification des capacités de DPU

Vous pouvez utiliser les métriques des tâches AWS Glue pour estimer le nombre d'unités de traitement de données (DPUs) qui peuvent être utilisées pour étendre un AWS Glue travail.

Note

Cette page s'applique uniquement aux AWS Glue versions 0.9 et 1.0. Les versions ultérieures de AWS Glue contiennent des fonctionnalités de réduction des coûts qui introduisent des considérations supplémentaires lors de la planification des capacités.

Rubriques

- [Code profilé](#)
- [Visualisez les métriques profilées sur le AWS Glue console](#)
- [Déterminer la capacité DPU optimale](#)

Code profilé

Le script suivant lit une partition Amazon Simple Storage Service (Amazon S3) contenant 428 fichiers JSON compressés avec gzip. Le script applique un mappage pour modifier les noms de champs, les convertit et les écrit dans Amazon S3 au format Apache Parquet. Vous DPU en attribuez 10 par défaut et vous exécutez cette tâche.

```
datasource0 = glueContext.create_dynamic_frame.from_options(connection_type="s3",
    connection_options = {"paths": [input_path],
    "useS3ListImplementation":True,"recurse":True}, format="json")
applymapping1 = ApplyMapping.apply(frame = datasource0, mappings = [(map_spec)])
datasink2 = glueContext.write_dynamic_frame.from_options(frame = applymapping1,
    connection_type = "s3", connection_options = {"path": output_path}, format =
    "parquet")
```

Visualisez les métriques profilées sur le AWS Glue console

Exécution de tâche 1 : Dans cette exécution de tâche, nous montrons comment déterminer si le cluster est sous-approvisionné DPU. La fonctionnalité d'exécution des tâches dans AWS Glue indique le [nombre total d'exécuteurs actifs](#), le [nombre d'étapes terminées](#) et le [nombre maximal d'exécuteurs nécessaires](#).

Le nombre maximum de programmes d'exécution nécessaires est calculé en ajoutant le nombre total de tâches en cours d'exécution et de tâches en attente, puis en divisant ce nombre par le nombre de tâches par programme d'exécution. Ce résultat est une mesure du nombre total d'exécuteurs requises pour satisfaire la charge du moment.


En revanche, le nombre de programmes d'exécution actifs en cours d'exécution mesure le nombre de programmes d'exécution qui exécutent des tâches Apache Spark. À mesure que la tâche progresse, le nombre maximum de programmes d'exécution nécessaires peut varier et baisse généralement vers la fin de la tâche à mesure que diminue la file d'attente de tâches en attente.

La ligne rouge horizontale du graphique suivant indique le nombre maximum d'exécuteurs alloués, qui dépend du nombre d'exécuteurs DPU que vous allouez à la tâche. Dans ce cas, vous allouez

10 points DPUs à l'exécution du job. Une DPU est réservée à la gestion. Neuf DPUs exécutent deux exécutants chacun et un exécutant est réservé au pilote Spark. Le pilote Spark s'exécute dans l'application principale. Par conséquent, le nombre maximum de programmes d'exécution alloués est de $2 \times 9 - 1 = 17$ programmes d'exécution.

Jobs > e2e-dpus


Detailed job metrics



Comme le montre le graphique, le nombre maximum de programmes d'exécution nécessaires commence à 107 au début de la tâche, alors que le nombre de programmes d'exécution actifs reste 17. C'est le même que le nombre maximum d'exécutants alloués, soit 10 DPUs. Le ratio entre le nombre maximum de programmes d'exécution nécessaires et le nombre maximum de programmes d'exécution alloués (en ajoutant 1 à chacun des pilotes Spark) donne le facteur sous-alloué : $108/18 = 6x$. Vous pouvez en configurer 6 (sous le ratio de provisionnement) * 9 (capacité actuelle du DPU - 1) + 1 DPUs = 55 DPUs pour étendre le travail afin de l'exécuter avec un parallélisme maximal et de terminer plus rapidement.

La console AWS Glue affiche le détail des métriques des tâches sous la forme d'une ligne statique qui représente le nombre maximal de programmes d'exécution alloués au départ. Pour ces métriques, la console calcule le nombre maximum de programme d'exécution alloués à partir de la définition de la tâche. En revanche, pour les métriques détaillées d'exécution des tâches, la console calcule le nombre maximum d'exécutants alloués à partir de la configuration d'exécution des tâches, en particulier le nombre DPUs alloué pour l'exécution des tâches. Pour afficher les métriques d'une

exécution de tâche spécifique, sélectionnez l'exécution et choisissez View run metrics (Afficher les métriques de l'exécution).




Si l'on regarde les octets Amazon S3 [lus](#) et [écrits](#), on remarque que la tâche prend six minutes complètes pour diffuser les données à partir d'Amazon S3 et les écrire en parallèle. Tous les cœurs alloués DPUs lisent et écrivent sur Amazon S3. Le nombre maximum de programmes d'exécution nécessaires (107) correspond également au nombre de fichiers dans le chemin d'accès d'entrée Amazon S3 (428). Chaque programme d'exécution peut lancer quatre tâches Spark pour traiter quatre fichiers d'entrée (JSON compressées avec gzip).

Déterminer la capacité DPU optimale

Sur la base des résultats de l'exécution de la tâche précédente, vous pouvez augmenter le nombre total de tâches allouées DPUs à 55 et suivre les performances de la tâche. La tâche se termine en moins de trois minutes, soit la moitié du temps auparavant nécessaire. La montée en charge de la tâche n'est pas linéaire dans ce cas, car il s'agit d'une tâche d'exécution courte. Les tâches comportant des tâches de longue durée ou un grand nombre de tâches (un grand nombre d'exécuteurs maximum nécessaires) bénéficient d'une accélération des performances du close-to-linear DPU grâce à la scale-out.

Jobs > e2e-dpus


Detailed job metrics



Comme le montre l'image ci-dessus, le nombre total de programmes d'exécution actifs atteint le nombre maximum de programmes d'exécution alloués (107). De même, le nombre maximum de programmes d'exécution nécessaires ne dépasse jamais le nombre maximum de programmes d'exécution alloués. Le nombre maximum de programmes d'exécution nécessaires est calculé à partir du nombre de tâches en cours d'exécution et en attente, il doit donc être inférieur au nombre de programmes d'exécution actifs. Ceci est dû au fait que des programmes d'exécution peuvent être partiellement ou complètement inactifs pour une courte période de temps et ne sont pas encore démagnétisés.

Jobs > e2e-dpus


Detailed job metrics



Cette exécution de tâche utilise 6 fois plus de programmes d'exécution pour lire et écrire en parallèle depuis Amazon S3. Par conséquent, cette exécution de tâche utilise plus de bande passante Amazon S3 pour les lectures et les écritures, et se termine plus rapidement.

Identifiez le surprovisionnement DPUs

Ensuite, vous pouvez déterminer si le fait d'étendre la tâche à 100 DPUs ($99 \times 2 = 198$ exécuteurs) permet de l'étendre davantage. Comme le montre le graphique suivant, la tâche se termine toujours après trois minutes. De même, la tâche ne dépasse pas 107 exécuteurs (DPUconfiguration 55), et les 91 exécuteurs restants sont surapprovisionnés et ne sont pas du tout utilisés. Cela montre que l'augmentation du nombre de n' DPUs améliore pas toujours les performances, comme en témoigne le nombre maximal d'exécuteurs nécessaires.



Comparer des différences de temps

Les trois cycles de travail présentés dans le tableau suivant résument les temps d'exécution des travaux pour 10 DPUs DPUs, 55 et 100 DPUs. Vous pouvez trouver la capacité de DPU pour améliorer la durée d'exécution de la tâche en utilisant l'estimation que vous avez réalisée en surveillant la première exécution de tâche.

ID de tâche	Nombre de DPUs	Durée d'exécution
jr_c894524c8ef5048a4d9...	10	6 min.
jr_1a466cf2575e7ffe6856...	55	3 min.
jr_34fa1ed4c6aa9ff0a814...	100	3 min.

Résolution des problèmes liés à l'IA générative pour Apache Spark in AWS Glue

Le dépannage génératif de l'IA pour Apache Spark Preview est disponible pour les jobs exécutés sur AWS AWS Glue 4.0 et Glue 5.0, ainsi que dans les AWS régions suivantes :

- USA Est (Virginie du Nord)
- USA Est (Ohio)
- USA Ouest (Oregon)
- USA Ouest (Californie du Nord)
- Amérique du Sud (São Paulo)
- Canada (Centre)
- Europe (Irlande)
- Europe (Londres)
- Europe (Paris)
- Europe (Stockholm)
- Europe (Milan)
- Europe (Francfort)
- Moyen-Orient (Bahreïn)
- Moyen-Orient (EAU)
- Afrique (Le Cap)
- Asie-Pacifique (Tokyo)
- Asie-Pacifique (Hong Kong)
- Asie-Pacifique (Mumbai)
- Asie-Pacifique (Singapour)
- Asie-Pacifique (Jakarta)
- Asie-Pacifique (Séoul)
- Asie-Pacifique (Osaka)
- Asie-Pacifique (Sydney)

Les fonctionnalités de prévisualisation sont susceptibles d'être modifiées.

La résolution des problèmes liés à l'IA générative pour les tâches Apache Spark dans AWS Glue est une nouvelle fonctionnalité qui aide les ingénieurs de données et les scientifiques à diagnostiquer et à résoudre facilement les problèmes dans leurs applications Spark. Utilisant les technologies d'apprentissage automatique et d'IA générative, cette fonctionnalité analyse les problèmes liés aux

tâches Spark et fournit une analyse détaillée des causes profondes ainsi que des recommandations pratiques pour les résoudre.

Comment fonctionne le dépannage par IA générative pour Apache Spark ?

Pour les tâches Spark qui ont échoué, Generative AI Troubleshooting analyse les métadonnées des tâches ainsi que les indicateurs et journaux précis associés à la signature d'erreur de votre tâche afin de générer une analyse des causes premières, et recommande des solutions spécifiques et les meilleures pratiques pour aider à remédier aux échecs de tâches.

Configuration de la résolution des problèmes liés à l'IA générative pour Apache Spark pour vos tâches

Configuration des autorisations IAM

L'octroi d'autorisations à l'utilisateur APIs utilisé par Spark Troubleshooting pour vos tâches dans AWS Glue nécessite les autorisations IAM appropriées. Vous pouvez obtenir des autorisations en associant la AWS politique personnalisée suivante à votre identité IAM (comme un utilisateur, un rôle ou un groupe).

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:StartCompletion",
        "glue:GetCompletion"
      ],
      "Resource": [
        "arn:aws:glue:*:*:completion/*",
        "arn:aws:glue:*:*:job/*"
      ]
    }
  ]
}
```

Note

Pendant la version préliminaire, Spark Troubleshooting n' APIs est pas disponible via le AWS SDK que vous pouvez utiliser par programmation. APIs Les deux éléments suivants

sont utilisés dans la politique IAM pour permettre cette expérience via la console AWS Glue Studio : `StartCompletion` et `GetCompletion`.

Attribution d'autorisations

Pour activer l'accès, ajoutez des autorisations à vos utilisateurs, groupes ou rôles :

- Pour les utilisateurs et les groupes dans IAM Identity Center : créez un ensemble d'autorisations. Suivez les instructions de la section [Création d'un ensemble d'autorisations](#) dans le guide de l'utilisateur d'IAM Identity Center.
- Pour les utilisateurs gérés dans IAM via un fournisseur d'identité : créez un rôle pour la fédération des identités. Suivez les instructions de la section [Création d'un rôle pour un fournisseur d'identité tiers \(fédération\)](#) dans le guide de l'utilisateur IAM.
- Pour les utilisateurs IAM : créez un rôle que votre utilisateur peut assumer. Suivez les instructions de la section [Création d'un rôle pour un utilisateur IAM](#) dans le guide de l'utilisateur IAM.

Exécution d'une analyse de résolution des problèmes suite à l'échec d'une tâche

Vous pouvez accéder à la fonctionnalité de dépannage via plusieurs chemins dans la console AWS Glue. Voici comment commencer :

Option 1 : depuis la page Liste des tâches

1. Ouvrez la console AWS Glue à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le volet de navigation, sélectionnez ETL Jobs.
3. Localisez votre tâche qui a échoué dans la liste des tâches.
4. Sélectionnez l'onglet Exécutions dans la section des détails de la tâche.
5. Cliquez sur le job qui a échoué que vous souhaitez analyser.
6. Choisissez Résoudre les problèmes avec l'IA pour démarrer l'analyse.
7. Lorsque l'analyse de résolution des problèmes est terminée, vous pouvez consulter l'analyse des causes premières et les recommandations dans l'onglet Analyse de résolution des problèmes en bas de l'écran.

extract-highway-data

Last modified on 11/21/2024, 9:32:05 PM

Actions Save Run

Script Job details Runs Data quality Schedules Version Control

Script Info

```
1 import sys
2 from awsglue.transforms import *
3 from awsglue.utils import getResolvedOptions
4 from pyspark.context import SparkContext
5 from awsglue.context import GlueContext
6 from awsglue.job import Job
7
8 ## @params: [JOB_NAME]
9 args = getResolvedOptions(sys.argv, ['JOB_NAME'])
10
11 sc = SparkContext()
12 glueContext = GlueContext(sc)
13 spark = glueContext.spark_session
14 job = Job(glueContext)
15 job.init(args['JOB_NAME'], args)
16
17 # read from a partition corresponding to a day in usa-traffic data in 2024
18 S3DataSource_dsourcel = glueContext.create_dynamic_frame_from_options(
19     format_options={},
20     connection_type="s3",
21     format="json",
22     connection_options={"paths": ["s3://usa-traffic-dat/routes/2024/11/15"]},
23     transformation_ctx="S3DataSource_dsourcel",
24 )
25
26 # filter the data to select only routes for highways
```


Python Ln 1, Col 1 Errors: 0 Warnings: 0

CloudShell Feedback

© 2024, Amazon Web Services, Inc. or its affiliates. Privacy Terms Cookie preferences

Option 2 : utilisation de la page Job Run Monitoring

1. Accédez à la page de surveillance de l'exécution des tâches.
2. Localisez l'exécution de votre tâche qui a échoué.
3. Choisissez le menu déroulant Actions.
4. Choisissez Résoudre les problèmes avec l'IA.



Option 3 : depuis la page Détails du Job Run

1. Accédez à la page des détails de l'exécution de votre tâche qui a échoué en cliquant sur Afficher les détails d'une exécution échouée dans l'onglet Exécutions ou en sélectionnant l'exécution du travail sur la page de surveillance des exécutions de tâches.
2. Sur la page des détails de l'exécution des tâches, recherchez l'onglet Analyser les problèmes.

Catégories de résolution des problèmes prises en charge (version préliminaire)

Ce service se concentre sur trois catégories principales de problèmes que les ingénieurs de données et les développeurs rencontrent fréquemment dans leurs applications Spark :

- Erreurs de configuration et d'accès aux ressources : lors de l'exécution d'applications Spark dans AWS Glue, les erreurs de configuration des ressources et d'accès figurent parmi les problèmes les plus courants mais les plus difficiles à diagnostiquer. Ces erreurs se produisent souvent lorsque votre application Spark tente d'interagir avec AWS des ressources mais rencontre des problèmes d'autorisation, des ressources manquantes ou des problèmes de configuration.
- Problèmes de mémoire liés au pilote Spark et à l'exécuteur : les erreurs liées à la mémoire dans les tâches Apache Spark peuvent être complexes à diagnostiquer et à résoudre. Ces erreurs se

produisent souvent lorsque vos exigences en matière de traitement des données dépassent les ressources de mémoire disponibles, que ce soit sur le nœud pilote ou sur les nœuds exécutants.

- Problèmes de capacité du disque Spark : les erreurs liées au stockage dans les tâches AWS Glue Spark apparaissent souvent lors d'opérations de remaniement, de fuite de données ou lors de transformations de données à grande échelle. Ces erreurs peuvent être particulièrement délicates car elles peuvent ne pas se manifester avant que votre tâche ne soit en cours d'exécution pendant un certain temps, ce qui peut entraîner une perte de temps et de ressources de calcul précieux.

Note

Avant de mettre en œuvre les modifications suggérées dans votre environnement de production, examinez-les attentivement. Le service fournit des recommandations basées sur des modèles et des meilleures pratiques, mais votre cas d'utilisation spécifique peut nécessiter des considérations supplémentaires.

Diffusion de jobs ETL dans AWS Glue

Vous pouvez créer des tâches Extract-transform-load (ETL) qui s'exécutent continuellement et consomment des données provenant de sources en streaming telles que Amazon Kinesis Data Streams, Apache Kafka et Amazon Managed Streaming for Apache Kafka (Amazon MSK). Les tâches nettoient et transforment les données, puis chargent les résultats dans les lacs de données Amazon S3 ou les magasins de données JDBC.

En outre, vous pouvez produire des données pour des flux Amazon Kinesis Data Streams. Cette fonctionnalité n'est disponible que lors de l'écriture de AWS Glue scripts. Pour de plus amples informations, veuillez consulter [the section called “Connexions Kinesis”](#).

Par défaut, AWS Glue traite et écrit les données dans des fenêtres de 100 secondes. Cela permet de traiter les données de manière efficace et d'effectuer des agrégations sur les données qui arrivent plus tard que prévu. Vous pouvez modifier la taille de cette fenêtre temporelle pour augmenter la ponctualité ou la précision de l'agrégation. AWS Glue les tâches de streaming utilisent des points de contrôle plutôt que des signets de tâches pour suivre les données lues.

 Note

AWS Glue facture toutes les heures pour les tâches ETL diffusées en continu pendant leur exécution.

Cette vidéo aborde les défis liés aux coûts du streaming ETL et les fonctionnalités de réduction des coûts dans AWS Glue.

La création d'une tâche ETL en streaming implique les étapes suivantes :

1. Pour une source de streaming Apache Kafka, créez un AWS Glue connexion à la source Kafka ou au cluster Amazon MSK.
2. Créez manuellement une table du catalogue de données pour la source en streaming.
3. Créez une tâche ETL pour la source de données de streaming. Définissez des propriétés de tâche spécifiques au streaming et fournissez votre propre script ou modifiez éventuellement le script généré.

Pour de plus amples informations, veuillez consulter [Streaming d'ETL en AWS Glue](#).

Lorsque vous créez une tâche ETL de streaming pour Amazon Kinesis Data Streams, il n'est pas nécessaire de créer un AWS Glue connexion. Toutefois, s'il existe une connexion attachée au AWS Glue une tâche ETL de streaming utilisant Kinesis Data Streams comme source, puis un point de terminaison de cloud privé virtuel (VPC) vers Kinesis est requis. Pour plus d'informations, consultez [Création d'un point de terminaison d'interface](#) dans le Guide de l'utilisateur Amazon VPC. Lorsque vous spécifiez un Amazon Kinesis Data Streams dans un autre compte, vous devez configurer les rôles et les stratégies pour autoriser l'accès entre comptes. Pour de plus amples informations, veuillez consulter la rubrique [Exemple : Lire à partir d'un flux Kinesis dans un autre compte](#).

AWS Glue les tâches ETL de streaming peuvent détecter automatiquement les données compressées, les décompresser de manière transparente, effectuer les transformations habituelles sur la source d'entrée et les charger dans le magasin de sortie.

AWS Glue prend en charge la décompression automatique pour les types de compression suivants en fonction du format d'entrée :

Type de compression	Fichier Avro	Référence Avro	JSON	CSV	Grok
BZIP2	Oui	Oui	Oui	Oui	Oui
GZIP	Non	Oui	Oui	Oui	Oui
SNAPPY	Oui (format Snappy brut)	Oui (format Snappy encadré)	Oui (format Snappy encadré)	Oui (format Snappy encadré)	Oui (format Snappy encadré)
XZ	Oui	Oui	Oui	Oui	Oui
ZSTD	Oui	Non	Non	Non	Non
DEFLATE	Oui	Oui	Oui	Oui	Oui

Rubriques

- [Création d'un AWS Glue connexion pour un flux de données Apache Kafka](#)
- [Création d'un tableau de catalogue de données pour une source en streaming](#)
- [Notes et restrictions pour les sources en streaming Avro](#)
- [Application de modèles Grok à des sources de streaming](#)
- [Définition des propriétés de tâche pour une tâche ETL en streaming](#)
- [Restrictions et notes sur ETL en streaming](#)

Création d'un AWS Glue connexion pour un flux de données Apache Kafka

Pour lire un flux Apache Kafka, vous devez créer un AWS Glue connexion.

Pour créer un AWS Glue connexion pour une source Kafka (console)

1. Ouvrez la AWS Glue console à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le volet de navigation, sous Data catalog (Catalogue de données), choisissez Connexions (Connexions).
3. Choisissez Add connection (Ajouter une connexion), et dans la page Set up your connection's properties (Configurer les propriétés de votre connexion), saisissez un nom de connexion.

 Note

Pour plus d'informations sur la spécification des propriétés de connexion, veuillez consulter [Propriétés de connexion AWS Glue](#).

4. Pour Type de connexion, choisissez Kafka.
5. Pour les serveurs bootstrap Kafka URLs, entrez l'hôte et le numéro de port des courtiers bootstrap pour votre cluster Amazon MSK ou votre cluster Apache Kafka. Utilisez uniquement des points de terminaison utilisant le protocole TLS (Transport Layer Security) pour établir la connexion initiale au cluster Kafka. Les points de terminaison en texte brut ne sont pas pris en charge.

Voici un exemple de liste de paires de nom d'hôte et de numéro de port pour un cluster Amazon MSK.

```
myserver1.kafka.us-east-1.amazonaws.com:9094,myserver2.kafka.us-east-1.amazonaws.com:9094,myserver3.kafka.us-east-1.amazonaws.com:9094
```

Pour plus d'informations sur l'obtention des informations du broker d'amorçage, veuillez consulter la rubrique [Obtenir les brokers d'amorçage pour un cluster Amazon MSK](#) dans le Guide du développeur Amazon Managed Streaming for Apache Kafka.

6. Si vous souhaitez une connexion sécurisée à la source de données Kafka, sélectionnez Require SSL connection (Connexion SSL obligatoire), et pour Kafka private CA certificate location (Emplacement du certificat d'autorité de certification privée Kafka), entrez un chemin d'accès Amazon S3 valide vers un certificat SSL personnalisé.

Pour une connexion SSL à Kafka autogérée, le certificat personnalisé est obligatoire. Il est facultatif pour Amazon MSK.

Pour plus d'informations sur la spécification d'un certificat personnalisé pour Kafka, consulter [the section called "Propriétés de connexion SSL"](#).

7. Utilisez AWS Glue Studio la AWS CLI pour spécifier une méthode d'authentification du client Kafka. Pour y accéder, AWS Glue Studio AWS Glue sélectionnez dans le menu ETL du volet de navigation de gauche.

Pour plus d'informations sur les méthodes d'authentification client Kafka, consultez [AWS Glue Propriétés de connexion Kafka pour l'authentification du client](#) .

8. Saisissez éventuellement une description, puis choisissez Suivant.
9. Pour un cluster Amazon MSK, spécifiez son Virtual Private Cloud (VPC), son sous-réseau et son groupe de sécurité. Les informations du VPC sont facultatives pour Kafka autogéré.
10. Choisissez Next (Suivant) pour vérifier toutes les propriétés de connexion, puis choisissez Finish (Terminer).

Pour plus d'informations sur AWS Glue connexions, voir [Connexion aux données](#).

AWS Glue Propriétés de connexion Kafka pour l'authentification du client

Authentification SASL/GSSAPI (Kerberos)

Le choix de cette méthode d'authentification vous permettra de spécifier les propriétés Kerberos.

Kerberos Keytab

Choisissez l'emplacement du fichier keytab. Un keytab stocke les clés à long terme pour un ou plusieurs principaux. Pour en savoir plus, consultez [Documentation du MIT Kerberos : Keytab](#).

Fichier Kerberos krb5.conf

Choisissez le fichier krb5.conf. Il contient le domaine par défaut (un réseau logique, similaire à un domaine, qui définit un groupe de systèmes sous le même KDC) et l'emplacement du serveur KDC. Pour en savoir plus, consultez [Documentation MIT Kerberos : krb5.conf](#).

Principal Kerberos et nom de service Kerberos

Saisissez le principal Kerberos et le nom de service Kerberos. Pour plus d'informations, consultez [MIT Kerberos Documentation: Kerberos principal](#) (Documentation du MIT Kerberos : principal Kerberos).

Authentification SASL/SCRAM-SHA-512

Le choix de cette méthode d'authentification vous permettra de spécifier les informations d'identification d'authentification.

AWS Secrets Manager

Recherchez votre jeton dans la zone Search (Rechercher) en saisissant son nom ou son ARN.

Nom d'utilisateur et mot de passe du fournisseur directement

Recherchez votre jeton dans la zone Search (Rechercher) en saisissant son nom ou son ARN.

Authentification SSL client

Le choix de cette méthode d'authentification vous permet de sélectionner l'emplacement du centre de stockage des clés client Kafka en naviguant sur Amazon S3. Vous pouvez également entrer le mot de passe du centre de stockage des clés client Kafka et le mot de passe de la clé client Kafka.

Authentification IAM

Cette méthode d'authentification ne nécessite aucune spécification supplémentaire et n'est applicable que lorsque la source de diffusion en direct est MSK Kafka.

Authentification SASL/PLAIN

Le choix de cette méthode d'authentification vous permet de spécifier des informations d'authentification.

Création d'un tableau de catalogue de données pour une source en streaming

Une table du catalogue de données qui spécifie les propriétés du flux de données source, y compris le schéma de données, peut être créée manuellement pour une source de streaming. Cette table est utilisée comme source de données pour la tâche ETL en streaming.

Si vous ne connaissez pas le schéma des données dans le flux de données source, vous pouvez créer la table sans schéma. Ensuite, lorsque vous créez la tâche ETL de streaming, vous pouvez activer AWS Glue fonction de détection de schéma. AWS Glue détermine le schéma à partir des données de streaming.

Utilisation de la [AWS Glue console](#), le AWS Command Line Interface (AWS CLI) ou le AWS Glue API pour créer la table. Pour plus d'informations sur la création manuelle d'une table à l'aide du AWS Glue console, voir [the section called “Création de tables”](#).

Note

Vous ne pouvez pas utiliser la AWS Lake Formation console pour créer la table ; vous devez utiliser AWS Glue console.

Tenez également compte des informations suivantes pour les sources en streaming au format Avro ou pour les données de journal auxquelles vous pouvez appliquer des modèles Grok.

- [the section called “Notes et restrictions pour les sources en streaming Avro”](#)
- [the section called “Application de modèles Grok à des sources de streaming”](#)

Rubriques

- [Source de données Kinesis](#)
- [Source de données Kafka](#)
- [AWS Glue Source de la table de registre des schémas](#)

Source de données Kinesis

Lors de la création de la table, définissez les propriétés de streaming ETL suivantes (console).

Type de source

Kinesis

Pour une source Kinesis dans le même compte :

Région

AWS Région dans laquelle réside le service Amazon Kinesis Data Streams. Le nom de la région et du flux Kinesis sont convertis en un ARN de flux.

Exemple : <https://kinesis.us-east-1.amazonaws.com>

Nom du flux Kinesis

Nom du flux comme décrit dans [Création d'un flux](#) dans le Guide du développeur d'Amazon Kinesis Data Streams.

Pour obtenir une source Kinesis dans un autre compte, reportez-vous à [Cet exemple](#) pour configurer les rôles et les stratégies pour autoriser un accès entre comptes. Configurez ces paramètres :

ARN du flux de diffusion

ARN du flux de données Kinesis auprès duquel le consommateur est enregistré. Pour plus d'informations, consultez les [sections Amazon Resource Names \(ARNs\) et AWS Service Namespaces](#) dans le Références générales AWS.

ARN du rôle assumé

Amazon Resource Name (ARN) du rôle à assumer.

Nom de la séance (facultatif)

Identifiant de la séance du rôle assumé.

Utilisez le nom de séance de rôle pour identifier de manière unique une séance lorsque le même rôle est assumé par différents principaux ou pour différentes raisons. Dans les scénarios impliquant plusieurs comptes, le nom de séance de rôle est visible et peut être enregistré par le compte propriétaire du rôle. Le nom de la séance de rôle est également utilisé dans l'ARN du principal de rôle présumé. Cela signifie que les demandes d'API inter-comptes ultérieures utilisant les informations d'identification de sécurité temporaires exposeront le nom de session du rôle au compte externe dans ses AWS CloudTrail journaux.

Pour définir les propriétés ETL de streaming pour Amazon Kinesis Data Streams (AWS Glue API AWS CLI(ou)

- Pour configurer les propriétés ETL de streaming pour une source Kinesis dans le même compte, spécifiez les paramètres `streamName` et `endpointUrl` dans la structure `StorageDescriptor` de l'opération d'API `CreateTable` ou de la commande `create_table` de la CLI.

```
"StorageDescriptor": {  
  "Parameters": {  
    "typeOfData": "kinesis",  
    "streamName": "sample-stream",  
    "endpointUrl": "https://kinesis.us-east-1.amazonaws.com"  
  }  
  ...  
}
```

Ou, spécifiez le `streamARN`.

Exemple

```
"StorageDescriptor": {  
  "Parameters": {  
    "typeOfData": "kinesis",  
    "streamARN": "arn:aws:kinesis:us-east-1:123456789:stream/sample-stream"  
  }  
}
```

```
}  
...  
}
```

- Pour configurer les propriétés ETL de streaming pour une source Kinesis dans un autre compte, spécifiez les paramètres `streamARN`, `awsSTSRoleARN` et `awsSTSSessionName` (facultatif) dans la structure `StorageDescriptor` de l'opération d'API `CreateTable` ou de la commande `create_table` de la CLI.

```
"StorageDescriptor": {  
  "Parameters": {  
    "typeOfData": "kinesis",  
    "streamARN": "arn:aws:kinesis:us-east-1:123456789:stream/sample-stream",  
    "awsSTSRoleARN": "arn:aws:iam::123456789:role/sample-assume-role-arn",  
    "awsSTSSessionName": "optional-session"  
  }  
  ...  
}
```

Source de données Kafka

Lors de la création de la table, définissez les propriétés de streaming ETL suivantes (console).

Type de source

Kafka

Pour une source Kafka :

Nom de la rubrique

Nom de la rubrique tel que spécifié dans Kafka.

Connexion

Un AWS Glue connexion qui fait référence à une source Kafka, comme décrit dans [the section called “Création d'une connexion pour un flux de données Kafka”](#).

AWS Glue Source de la table de registre des schémas

Pour utiliser AWS Glue Registre des schémas pour les tâches de streaming, suivez les instructions de la section [Cas d'utilisation : AWS Glue Data Catalog](#) pour créer ou mettre à jour une table de registre de schéma.

À l'heure actuelle, AWS Glue Le streaming ne prend en charge que le format Glue Schema Registry Avro avec une inférence de schéma définie sur `false`

Notes et restrictions pour les sources en streaming Avro

Les notes et restrictions suivantes s'appliquent aux sources en streaming au format Avro :

- Lorsque la détection du schéma est activée, le schéma Avro doit être inclus dans la charge utile. Lorsqu'elle est désactivée, la charge utile ne doit contenir que des données.
- Certains types de données Avro ne sont pas pris en charge dans les trames dynamiques. Vous ne pouvez pas spécifier ces types de données lorsque vous définissez le schéma à l'aide de la page Définir un schéma de l'assistant de création de table du AWS Glue console. Lors de la détection de schéma, les types non pris en charge dans le schéma Avro sont convertis en types pris en charge comme suit :
 - `EnumType` => `StringType`
 - `FixedType` => `BinaryType`
 - `UnionType` => `StructType`
- Si vous définissez le schéma de table à l'aide de la page Define a schema (Définir un schéma) dans la console, le type de l'élément racine implicite pour le schéma est `record`. Si vous voulez un type d'élément racine autre que `record`, par exemple, `array` ou `map`, vous ne pouvez pas spécifier le schéma à l'aide de la page Define a schema (Définir un schéma). Au lieu de cela, vous devez ignorer cette page et spécifier le schéma en tant que propriété de table ou dans le script ETL.
- Pour spécifier le schéma dans les propriétés de la table, complétez l'assistant de création de table, modifiez les détails de la table et ajoutez une nouvelle paire clé-valeur sous Table properties (Propriétés de la table). Utilisez la clé `avroSchema` et saisissez un objet de schéma JSON pour la valeur, comme illustré dans la capture d'écran suivante.

Edit table details

Key

Value

Description

Type description...

Table properties

Key	Value	
classification	avro	✕
avroSchema	<input style="font-family: monospace; font-size: 0.9em;" type="text" value='{"type": "array", "items": "string"}'/>	✕

- Pour spécifier le schéma dans le script ETL, modifiez l'instruction d'affectation `datasource0` et ajoutez la clé `avroSchema` à l'argument `additional_options`, comme indiqué dans les exemples Python et Scala suivants.

Python

```
SCHEMA_STRING = '{"type": "array", "items": "string"}'
datasource0 = glueContext.create_data_frame.from_catalog(database =
    "database", table_name = "table_name", transformation_ctx = "datasource0",
    additional_options = {"startingPosition": "TRIM_HORIZON", "inferSchema":
    "false", "avroSchema": SCHEMA_STRING})
```

Scala

```
val SCHEMA_STRING = """"{"type": "array", "items": "string"}""""
val datasource0 = glueContext.getCatalogSource(database = "database", tableName
    = "table_name", redshiftTmpDir = "", transformationContext = "datasource0",
```

```
additionalOptions = JsonOptions(s""""{"startingPosition": "TRIM_HORIZON",  
"inferSchema": "false", "avroSchema": "$SCHEMA_STRING"}""").getDataFrame()
```

Application de modèles Grok à des sources de streaming

Vous pouvez créer une tâche ETL en streaming pour une source de données de journalisation et utiliser des modèles Grok pour convertir les journaux en données structurées. La tâche ETL traite ensuite les données en tant que source de données structurée. Vous spécifiez les modèles Grok à appliquer lorsque vous créez la table du catalogue de données pour la source en streaming.

Pour plus d'informations sur les modèles Grok et les valeurs de chaînes de modèle personnalisées, veuillez consulter [Écriture de classifieurs personnalisés Grok](#).

Pour ajouter des modèles Grok au tableau du catalogue de données (console)

- Utilisez l'assistant de création de table et créez la table avec les paramètres spécifiés dans [the section called “Création d'un tableau de catalogue de données pour une source en streaming”](#). Spécifiez le format de données en tant que Grok, remplissez le champ Grok pattern (Modèle Grok), et éventuellement ajouter des modèles personnalisés sous Custom patterns (optional) (Modèles personnalisés – facultatif).

Choose a data format

Classification

☐ CSV

☐ JSON

☐ ORC

☐ Parquet

☐ Avro

☒ Grok

Choose the format of the data in your table.

Grok pattern

Built-in and custom named patterns used to parse your data into a structured schema. For more information, see the [list of built-in patterns](#).

Custom patterns

1

Optional custom building blocks for the grok pattern.

Appuyez sur Entrée après chaque modèle personnalisé.

Pour ajouter des modèles de grok à la table du catalogue de données (AWS Glue API AWS CLI(ou)

- Ajoutez le paramètre GrokPattern et, éventuellement, le paramètre CustomPatterns à l'opération d'API CreateTable ou à la commande create_table de la CLI.

```
"Parameters": {  
  ...  
  "grokPattern": "string",  
  "grokCustomPatterns": "string",  
  ...  
},
```

Formulez grokCustomPatterns en tant que chaîne et utilisez « \n » comme séparateur entre les motifs.

Voici un exemple de ces paramètres dans un fichier.

Exemple

```
"parameters": {  
  ...  
  "grokPattern": "%{USERNAME:username} %{DIGIT:digit:int}",  
  "grokCustomPatterns": "digit \d",  
  ...  
}
```

Définition des propriétés de tâche pour une tâche ETL en streaming

Lorsque vous définissez une tâche ETL de streaming dans AWS Glue console, fournissez les propriétés spécifiques aux flux suivantes. Pour obtenir la description d'autres propriétés de la tâche, consulter [Définition des propriétés des tâches Spark](#).

Rôle IAM

Spécifiez le rôle AWS Identity and Access Management (IAM) utilisé pour autoriser les ressources utilisées pour exécuter la tâche, accéder aux sources de streaming et accéder aux magasins de données cibles.

Pour accéder à Amazon Kinesis Data Streams, associez `AmazonKinesisFullAccess` AWS la politique gérée au rôle ou associez une politique IAM similaire qui permet un accès plus précis. Pour obtenir des exemples de stratégies, consultez [Controlling Access to Amazon Kinesis Data Streams Resources Using IAM](#) (Contrôle de l'accès aux ressources Amazon Kinesis Data Streams à l'aide d'IAM).

Pour plus d'informations sur les autorisations relatives à l'exécution de tâches dans AWS Glue, voir [Gestion des identités et des accès pour AWS Glue](#).

Type

Choisissez Spark Streaming.

AWS Glue version

Le AWS Glue version détermine les versions d'Apache Spark, de Python ou de Scala disponibles pour la tâche. Choisissez une sélection qui indique la version de Python ou de Scala disponible pour la tâche. AWS Glue version 2.0 avec prise en charge de Python 3 est la valeur par défaut pour les tâches ETL en streaming.

Fenêtre de maintenance

Spécifie une fenêtre dans laquelle une tâche de streaming peut être redémarrée. Consultez [the section called “Fenêtres de maintenance”](#).

Délai d'expiration de la tâche

Vous pouvez saisir une durée en minutes. La valeur par défaut est vide.

- Les tâches de streaming doivent avoir un délai d'expiration inférieur à 7 jours ou 10080 minutes.
- Lorsque la valeur est laissée vide, la tâche sera redémarrée au bout de 7 jours, si vous n'avez pas défini de fenêtre de maintenance. Si vous avez défini une fenêtre de maintenance, la tâche sera redémarrée pendant la fenêtre de maintenance au bout de 7 jours.

Source de données

Spécifiez la table que vous avez créée dans [the section called “Création d'un tableau de catalogue de données pour une source en streaming”](#).

Cible de données

Effectuez l'une des actions suivantes :

- Choisissez `Create tables in your data target` (Créer des tables dans votre cible de données) et spécifiez les propriétés de cible de données suivantes.

Banque de données

Choisissez Amazon S3 ou JDBC.

Format

Choisissez n'importe quel format. Tous sont pris en charge pour le streaming.

- Choisissez Use tables in the data catalog and update your data target (Utiliser les tables du catalogue de données et mettre à jour votre cible de données) et choisissez une table pour un magasin de données JDBC.

Définition du schéma en sortie

Effectuez l'une des actions suivantes :

- Choisissez Détecter automatiquement le schéma de chaque enregistrement pour activer la détection du schéma. AWS Glue détermine le schéma à partir des données de streaming.
- Choisissez Specify output schema for all records (Spécifier le schéma de sortie pour tous les enregistrements) pour utiliser la transformation Apply Mapping (Appliquer le mappage) pour définir le schéma en sortie.

Script

Vous pouvez également fournir votre propre script ou modifier le script généré pour effectuer des opérations prises en charge par le moteur Apache Spark Structured Streaming. Pour plus d'informations sur les opérations disponibles, consultez la section [Opérations sur le DataFrames streaming/Datasets](#).

Restrictions et notes sur ETL en streaming

Gardez à l'esprit les notes et restrictions suivantes :

- Décompression automatique pour AWS Glue les tâches ETL en streaming ne sont disponibles que pour les types de compression pris en charge. Veuillez prendre en compte les points suivants :
 - Le format Framed Snappy fait référence au [format de trame](#) officiel pour Snappy.
 - L'algorithme Deflate est pris en charge dans la version 3.0 de Glue et non dans la version 2.0.
- Lorsque vous utilisez la détection de schéma, vous ne pouvez pas effectuer de jointures de données en streaming.
- AWS Glue les tâches ETL en streaming ne prennent pas en charge le type de données Union pour AWS Glue Registre de schémas au format Avro.

- Votre script ETL peut utiliser AWS Glue et les transformations intégrées à Apache Spark Structured Streaming. Pour plus d'informations, voir [Opérations sur le DataFrames streaming/Datasets](#) sur le site Web d'Apache Spark ou. [AWS Glue PySpark transforme la référence](#)
- AWS Glue les tâches ETL en streaming utilisent des points de contrôle pour suivre les données lues. Par conséquent, une tâche arrêtée et redémarrée reprend là où elle s'est arrêtée dans le flux. Si vous souhaitez retraiter les données, vous pouvez supprimer le dossier du point de contrôle référencé dans le script.
- Les signets de tâche ne sont pas pris en charge.
- Pour utiliser la fonctionnalité de diffusion améliorée de Kinesis Data Streams dans tâche, consultez [the section called “Utilisation de la diffusion améliorée dans les tâches de streaming Kinesis”](#).
- Si vous utilisez une table de catalogue de données créée à partir de AWS Glue Registre des schémas, lorsqu'une nouvelle version de schéma est disponible, pour refléter le nouveau schéma, vous devez effectuer les opérations suivantes :
 1. Arrêtez les tâches associées à la table.
 2. Mettez à jour le schéma de la table Catalogue de données.
 3. Redémarrez les tâches associées à la table.

Record correspondant à AWS Lake Formation FindMatches

Note

Le rapprochement des records n'est actuellement pas disponible dans les régions suivantes de la AWS Glue console : Moyen-Orient (Émirats arabes unis), Europe (Espagne), Asie-Pacifique (Jakarta) et Europe (Zurich).

AWS Lake Formation fournit des fonctionnalités d'apprentissage automatique pour créer des transformations personnalisées afin de nettoyer vos données. Il existe actuellement une transformation disponible nommée FindMatches. La FindMatches transformation vous permet d'identifier les enregistrements dupliqués ou correspondants dans votre ensemble de données, même lorsque les enregistrements n'ont pas d'identifiant unique commun et qu'aucun champ ne correspond exactement. Cela ne nécessitera pas d'écrire de code ou de connaître le fonctionnement de l'apprentissage automatique. FindMatches peut être utile pour résoudre de nombreux problèmes, tels que :

- Correspondance de clients : liaison des enregistrements clients entre différentes bases de données client, même lorsque de nombreux champs client ne correspondent pas exactement entre les bases de données (par exemple, orthographe de nom différentes, adresses différentes, données manquantes ou inexacts, etc.).
- Correspondance de produits : correspondance des produits de votre catalogue par rapport à d'autres sources de produits, telle qu'un catalogue de produits par rapport au catalogue d'un concurrent, où les entrées sont structurées différemment.
- Amélioration de la détection des fraudes : identification de comptes client en double, afin de déterminer quand un nouveau compte est (ou peut être) une correspondance pour un utilisateur frauduleux précédemment connu.
- Autres problèmes de correspondance : correspondance d'adresses, de films, de listes de pièces, etc. En général, si un être humain pouvait examiner les lignes de votre base de données et déterminer si elles correspondent, il y a de fortes chances que la FindMatches transformation puisse vous aider.

Vous pouvez créer ces transformations lorsque vous créez une tâche. La transformation que vous créez est basée sur un schéma de magasin de données source et des exemples de données du jeu de données source que vous labélisez (nous appelons ce processus l'« enseignement » d'une transformation). Les enregistrements que vous labélisez doivent être présents dans le jeu de données source. Dans ce processus, nous générons un fichier que vous labélisez et chargez ensuite pour que la transformation apprenne d'une manière ou d'une autre. Après avoir enseigné votre transformation, vous pouvez l'appeler à partir de votre outil basé sur Spark AWS Glue job (PySpark ou Scala Spark) et utilisez-le dans d'autres scripts avec un magasin de données source compatible.

Une fois la transformation créée, elle est stockée dans AWS Glue. Sur le AWS Glue console, vous pouvez gérer les transformations que vous créez. Dans le volet de navigation sous Intégration des données et ETL, Outils de classification des données > Correspondance des enregistrements, vous pouvez modifier et continuer à entraîner votre transformation de machine learning. Pour de plus amples informations sur la gestion des transformations sur la console, veuillez consulter [Travailler avec l'apprentissage automatique transforme](#).

Note

AWS Glue les FindMatches tâches de la version 2.0 utilisent le compartiment Amazon S3 `aws-glue-temp-<accountID>-<region>` pour stocker des fichiers temporaires pendant que la transformation traite des données. Vous pouvez supprimer ces données une fois

l'exécution terminée, soit manuellement, soit en définissant une règle de cycle de vie Amazon S3.

Types de transformations Machine Learning

Vous pouvez créer des transformations de machine learning pour nettoyer vos données. Vous pouvez appeler ces transformations à partir de votre script ETL. Vos données passent d'une transformation à l'autre dans une structure de données appelée `DynamicFrame`, qui est une extension d'un `SQL Apache SparkDataFrame`. Le `DynamicFrame` contient vos données, et vous référencez son schéma pour traiter vos données.

Les types de transformations de machine learning suivants sont disponibles :

Recherche de correspondances

Recherche des enregistrements en double dans les données source. Vous enseignez cette transformation Machine Learning par l'étiquetage des ensembles de données afin d'indiquer les lignes qui correspondent. La transformation de machine learning apprend quelles lignes doivent être des correspondances à mesure que vous l'entraînez à l'aide d'exemples de données étiquetées. En fonction de la manière dont vous configurez la transformation, la sortie peut ressembler à l'une des suivantes :

- Une copie de la table d'entrée et une colonne `match_id` renseignée avec des valeurs qui indiquent des ensembles d'enregistrements correspondants. La colonne `match_id` est un identifiant arbitraire. Tous les enregistrements qui ont le même `match_id` ont été identifiés comme correspondant les uns aux autres. Les enregistrements avec des `match_id` différents ne correspondent pas.
- Une copie de la table d'entrée dans laquelle les lignes en double ont été retirées. Si plusieurs doublons sont trouvés, l'enregistrement avec la clé primaire la plus faible est conservé.

Rechercher des correspondances progressives

La transformation `FindMatches` peut également être configurée pour rechercher des correspondances entre les trames existantes et progressives et renvoyer en sortie une colonne contenant un ID unique par groupe de correspondances.

Pour plus d'informations, voir : [Recherche de correspondances progressives](#)

Utilisation de la FindMatches transformation

Vous pouvez utiliser la transformation FindMatches pour rechercher les enregistrements en double dans les données source. Un fichier d'étiquetage des données est généré ou fourni pour vous aider à enseigner à la transformation.

Note

Actuellement, les transformations FindMatches utilisant une clé de chiffrement personnalisée ne sont pas prises en charge dans les régions suivantes :

- Asie-Pacifique (Osaka) - ap-northeast-3

Pour commencer la FindMatches transformation, vous pouvez suivre les étapes ci-dessous. Pour un exemple plus avancé et détaillé, consultez le blog AWS Big Data : [Harmonize data using AWS Glue et du AWS Lake Formation FindMatches ML pour créer une vue à 360° du client](#).

Commencer à utiliser la transformation Recherche de correspondances

Suivez les étapes ci-après pour commencer à utiliser la transformation FindMatches :

1. Créez une table dans le AWS Glue Data Catalog pour les données source à nettoyer. Pour plus d'informations sur la création d'un robot d'exploration, voir [Travailler avec des robots d'exploration sur le AWS Glue Console](#).

Si vos données source sont dans un fichier texte, par exemple un fichier CSV (valeurs séparées par une virgule), tenez compte des éléments suivants :

- Placez votre fichier CSV des enregistrements d'entrée et le fichier d'étiquetage des données dans des dossiers distincts. Dans le cas contraire, le AWS Glue un robot d'exploration peut les considérer comme plusieurs parties d'une même table et créer des tables dans le catalogue de données de manière incorrecte.
- Sauf si votre fichier CSV inclut des caractères ASCII uniquement, assurez-vous que l'encodage UTF-8 sans marque d'ordre d'octet (BOM) est utilisé pour les fichiers CSV. Microsoft Excel ajoute souvent une marque d'ordre d'octet (BOM) au début de fichiers CSV UTF-8. Pour la retirer, ouvrez le fichier CSV dans un éditeur de texte, puis réenregistrez le fichier au format UTF-8 sans marque d'ordre d'octet (BOM).

2. Sur le AWS Glue console, créez une tâche et choisissez le type de transformation Find matches.

 Important

La table de sources de données que vous choisissez pour la tâche ne peut pas avoir plus de 100 colonnes.

3. Raconter AWS Glue pour générer un fichier d'étiquetage en choisissant Générer un fichier d'étiquetage. AWS Glue procède en premier lieu au regroupement d'enregistrements similaires pour chacun d'entre eux `labeling_set_id` afin que vous puissiez revoir ces regroupements. Vous labélisez les correspondances dans la colonne `label`.
 - Si vous disposez déjà d'un fichier d'étiquetage, c'est-à-dire un exemple d'enregistrements qui indiquent des lignes qui correspondent l'une à l'autre, téléchargez le fichier dans Amazon Simple Storage Service (Amazon S3). Pour en savoir plus sur le format du fichier d'étiquetage, consultez [Format du fichier d'étiquetage](#). Passez à l'étape 4.
4. Téléchargez le fichier d'étiquetage et labélisez le fichier comme décrit dans la section [Étiquetage](#).
5. Téléchargez le fichier étiqueté corrigé. AWS Glue exécute des tâches pour apprendre à la transformation comment trouver des correspondances.

Sur la page de liste Machine learning transforms (Transformations Machine Learning), choisissez l'onglet History (Historique). Cette page indique quand AWS Glue exécute les tâches suivantes :

- Importer des étiquettes
 - Exporter des étiquettes
 - Générer des étiquettes
 - Estimation de la qualité
6. Pour créer une meilleure transformation, vous pouvez télécharger, étiqueter, puis charger de manière itérative le fichier étiqueté. Lors des premières exécutions, beaucoup d'enregistrements peuvent ne pas correspondre. Mais AWS Glue apprend au fur et à mesure que vous continuez à l'enseigner en vérifiant le fichier d'étiquetage.
 7. Évaluez et ajustez votre transformation en évaluant les performances et les résultats des correspondances trouvées. Pour de plus amples informations, veuillez consulter [Le réglage de l'apprentissage automatique se transforme AWS Glue](#).

Étiquetage

Lorsque FindMatches génère un fichier d'étiquetage, les enregistrements sont sélectionnés à partir de votre table source. En fonction de l'entraînement précédent, FindMatches identifie les enregistrements les plus significatifs pouvant servir de base d'apprentissage.

L'acte d'étiquetage consiste à modifier un fichier d'étiquetage (nous vous suggérons d'utiliser une feuille de calcul Microsoft Excel, par exemple) et à ajouter des identifiants, ou étiquettes, dans la colonne `label` qui identifie les enregistrements correspondants ou non correspondants. Il est important d'avoir une définition claire et cohérente d'une correspondance dans vos données source. FindMatches apprend à partir des enregistrements que vous désignez comme correspondants (ou pas) et utilise vos décisions pour apprendre à rechercher des enregistrements en double.

Lorsqu'un fichier d'étiquetage est généré par FindMatches, environ 100 enregistrements sont générés. Ces 100 enregistrements sont généralement divisés en 10 jeux d'étiquetage, chaque jeu étant identifié par un `labeling_set_id` unique généré par FindMatches. Chaque jeu d'étiquetage doit être considéré comme une tâche d'étiquetage distincte indépendante des autres jeux d'étiquetage. Votre tâche consiste à identifier les enregistrements correspondants et non correspondants dans chaque jeu d'étiquetage.

Conseils pour modifier les fichiers d'étiquetage dans une feuille de calcul

Lorsque vous modifiez le fichier d'étiquetage dans une application de feuille de calcul, tenez compte des éléments suivants :

- Le fichier peut ne pas s'ouvrir avec les champs de colonne entièrement développés. Vous devrez peut-être développer les colonnes `label` et `labeling_set_id` pour voir le contenu de ces cellules.
- Si la colonne de clé primaire comporte un nombre, comme un type de données `long`, la feuille de calcul peut l'interpréter comme un nombre et modifier la valeur. La valeur de cette clé doit être traitée en tant que texte. Pour corriger ce problème, définissez le format Texte pour toutes les cellules de la colonne de clé primaire.

Format du fichier d'étiquetage

Le fichier d'étiquetage généré par AWS Glue pour enseigner votre FindMatches transformation utilise le format suivant. Si vous générez votre propre fichier pour AWS Glue, il doit également suivre le format suivant :

- Il s'agit d'un fichier CSV (valeurs séparées par des virgules).
- Il doit être encodé en UTF-8. Si vous modifiez le fichier à l'aide de Microsoft Windows, il peut être encodé avec cp1252.
- Il doit se trouver dans un emplacement Amazon S3 pour être transmis à AWS Glue.
- Utilisez un nombre modéré de lignes pour chaque tâche d'étiquetage. Il est recommandé d'utiliser 10 à 20 lignes par tâche, même si 2 à 30 lignes par tâche sont acceptées. Les tâches de plus de 50 lignes ne sont pas recommandées et peuvent entraîner de mauvais résultats ou une défaillance du système.
- Si vous disposez de données composées de paires d'enregistrements déjà marqués comme « correspondants » ou « non correspondants », cela ne pose pas de problème. Ces paires étiquetées peuvent être représentées sous forme de jeux d'étiquetage de taille 2. Dans ce cas, labélisez les deux enregistrements avec, par exemple, la lettre « A » s'ils correspondent, ou labélisez l'une avec la lettre « A » et l'autre avec la lettre « B » s'ils ne correspondent pas.

 Note

Étant donné qu'il comporte des colonnes supplémentaires, le fichier d'étiquetage a un schéma différent d'un fichier qui contient vos données source. Placez le fichier d'étiquetage dans un dossier différent de celui de tout fichier CSV d'entrée de transformation afin que AWS Glue crawler n'en tienne pas compte lorsqu'il crée des tables dans le catalogue de données. Dans le cas contraire, les tables créées par le AWS Glue il est possible que le robot d'exploration ne représente pas correctement vos données.

- Les deux premières colonnes (`labeling_set_id`, `label`) sont requises par AWS Glue. Les colonnes restantes doivent correspondre au schéma des données à traiter.
- Pour chaque `labeling_set_id`, vous identifiez tous les enregistrements correspondants à l'aide de la même étiquette. Une étiquette est une chaîne unique placée dans la colonne `label`. Nous vous recommandons d'utiliser les étiquettes contenant des caractères simples, par exemple A, B, C, et ainsi de suite. Les étiquettes sont sensibles à la casse et sont saisies dans la colonne `label`.
- Les lignes qui contiennent le même `labeling_set_id` et la même étiquette sont considérées comme formant une correspondance.
- Les lignes qui contiennent le même `labeling_set_id` et une étiquette différente sont considérées comme ne formant pas une correspondance.
- Les lignes qui contiennent un `labeling_set_id` différent sont considérées comme ne fournissant aucune information pour ou contre la correspondance.

Voici un exemple d'étiquetage de données :

labeling_set_id	étiquette	first_name	last_name	Anniversaire
ABC123	A	John	Doe	04/01/1980
ABC123	B	Jane	Smith	04/03/1980
ABC123	A	Johnny	Doe	04/01/1980
ABC123	A	Jon	Doe	04/01/1980
DEF345	A	Richard	Jones	12/11/1992
DEF345	A	Rich	Jones	11/12/1992
DEF345	B	Sarah	Jones	12/11/1992
DEF345	C	Richie	Jones Jr.	05/06/2017
DEF345	B	Sarah	Jones-Walker	12/11/1992
GHI678	A	Robert	Miller	1/3/1999
GHI678	A	Bob	Miller	1/3/1999
XYZABC	A	William	Robinson	2/5/2001
XYZABC	B	Andrew	Robinson	2/5/1971

- Dans l'exemple ci-dessus, nous identifions John/Johnny/Jon Doe as being a match and we teach the system that these records do not match Jane Smith. Separately, we teach the system that Richard and Rich Jones are the same person, but that these records are not a match to Sarah Jones/Jones -Walker et Richie Jones Jr.
- Comme vous pouvez le voir, la portée des étiquettes est limitée à l'élément `labeling_set_id`. Ainsi, les étiquettes ne dépassent pas les limites de `labeling_set_id`. Par exemple, une étiquette « A » dans `labeling_set_id` 1 n'a aucune relation avec l'étiquette « A » dans `labeling_set_id` 2.

- Si un enregistrement n'a aucune correspondance dans un jeu d'étiquettes, affectez-lui une étiquette unique. Par exemple, Jane Smith ne correspond à aucun enregistrement du jeu d'étiquettes ABC123, c'est donc le seul enregistrement de ce jeu d'étiquettes portant l'étiquette B.
- Le jeu d'étiquettes « GHI678 » indique qu'un ensemble d'étiquettes peut être composé uniquement de deux enregistrements auxquels est attribuée la même étiquette pour montrer qu'ils correspondent. De même, « XYZABC » montre deux enregistrements portant des étiquettes différentes pour montrer qu'ils ne correspondent pas.
- Notez que parfois un jeu d'étiquetage peut ne pas contenir de correspondances (c'est-à-dire que vous donnez à chaque enregistrement du jeu d'étiquetage une étiquette différente) ou qu'un jeu d'étiquetage peut être globalement « identique » (vous leur donnez le même label). Ceci est correct tant que vos jeux d'étiquetage contiennent collectivement des exemples d'enregistrements qui sont et ne sont pas « identiques » selon vos critères.

Important

Vérifiez que le rôle IAM auquel vous passez AWS Glue a accès au compartiment Amazon S3 qui contient le fichier d'étiquetage. Par convention, AWS Glue les politiques accordent l'autorisation aux compartiments ou dossiers Amazon S3 dont les noms sont préfixés par aws-glue -. Si vos fichiers d'étiquetage se trouvent dans un emplacement différent, ajoutez l'autorisation sur cet emplacement dans le rôle IAM.

Le réglage de l'apprentissage automatique se transforme AWS Glue

Vous pouvez ajuster vos transformations en machine learning AWS Glue pour améliorer les résultats de vos tâches de nettoyage des données afin d'atteindre vos objectifs. Pour améliorer votre transformation, vous pouvez l'entraîner en générant un ensemble d'étiquetage, en ajoutant des étiquettes, puis en répétant ces étapes plusieurs fois jusqu'à obtention des résultats souhaités. Vous pouvez également procéder à un réglage en modifiant certains paramètres de machine learning.

Pour de plus amples informations sur les transformations Machine Learning, veuillez consulter [Record correspondant à AWS Lake Formation FindMatches](#).

Rubriques

- [Mesures de Machine Learning](#)
- [Choisir entre la précision et le rappel](#)

- [Choisir entre l'exactitude et le coût](#)
- [Estimation de la qualité des correspondances à l'aide des notes de confiance des correspondances](#)
- [Entraîner la transformation à trouver des correspondances](#)

Mesures de Machine Learning

Pour comprendre les mesures qui sont utilisés pour régler votre transformation Machine Learning, vous devez vous familiariser avec la terminologie suivante :

Vrai positif (TP, True positive)

Correspondance dans les données correctement trouvée par la transformation, parfois appelée occurrence.

Vrai négatif (TN, True Negative)

Non correspondance dans les données que la transformation a correctement rejetée.

Faux positif (FP, False positive)

Non correspondance dans les données que la transformation a classifiée de manière incorrecte en tant que correspondance, parfois appelée fausse alarme.

Faux négatif (FN, False negative)

Correspondance dans les données que la transformation n'a pas trouvée, parfois appelée échec.

Pour de plus amples informations sur la terminologie utilisée dans le Machine Learning, consultez [Confusion matrix](#) dans Wikipedia.

Pour régler vos transformations Machine Learning, vous pouvez modifier la valeur des mesures suivantes dans les propriétés avancées de la transformation.

- Précision (Précision) évalue dans quelle mesure la transformation trouve de vrais positifs parmi le nombre total d'enregistrements qu'elle identifie comme positifs (vrais positifs et faux positifs). Pour en savoir plus, consultez [Précision et rappel](#) dans Wikipédia.
- Recall (Rappel) mesure comment la transformation trouve des vrais positifs à partir du nombre total d'enregistrements dans les données source. Pour en savoir plus, consultez [Précision et rappel](#) dans Wikipédia.
- Accuracy (Exactitude) mesure comment la transformation trouve des vrais positifs et des vrais négatifs. L'augmentation de la précision nécessite plus de ressources machine et des coûts

supérieurs. Mais elle entraîne également une augmentation du rappel. Pour en savoir plus, consulter [Précision et rappel](#) dans Wikipédia.

- Cost (Coût) mesure le nombre de ressources de calcul (et par conséquent le coût) consommées pour l'exécution de la transformation.

Choisir entre la précision et le rappel

Chaque transformation `FindMatches` contient un paramètre `precision-recall`. Vous utilisez ce paramètre pour spécifier l'un des éléments suivants :

- Si vous êtes plus préoccupé par le fait que la transformation indique de manière erronée que deux enregistrements sont des correspondances alors que ce n'est pas le cas, vous devez alors mettre l'accent sur la précision.
- Si vous êtes plus préoccupé par le fait que la transformation ne parvienne pas à détecter les enregistrements qui sont de réelles correspondances, vous devez mettre l'accent sur le rappel.

Vous pouvez faire ce compromis sur le AWS Glue console ou en utilisant le AWS Glue opérations d'API d'apprentissage automatique.

Dans quel cas favoriser la précision

Privilégiez la précision si vous êtes plus préoccupé par le risque que `FindMatches` se traduise par une paire d'enregistrements correspondants alors qu'il n'y a aucune correspondance réelle. Pour favoriser la précision, choisissez une valeur de compromis précision-rappel plus élevée. Avec une valeur plus élevée, la transformation `FindMatches` a besoin de plus de preuves pour décider qu'une paire d'enregistrements doivent correspondre. La transformation est réglée sur une tendance à indiquer que les enregistrements ne correspondent pas.

Par exemple, supposons que vous utilisez `FindMatches` pour détecter des articles en double dans un catalogue vidéo, et que vous fournissez une valeur précision-rappel plus élevée à la transformation. Si votre transformation détecte de manière incorrecte détecte qu' `Star Wars : Un nouvel espoir` est identique à `Star Wars : L'Empire contre-attaque`, un client qui souhaite `Un nouvel espoir` peut voir s'afficher `L'Empire contre-attaque`. Cela constituerait une mauvaise expérience client.

Toutefois, si la transformation ne parvient pas à détecter que `Star Wars : Un nouvel espoir` et `Star Wars : Episode IV - Un nouvel espoir` sont un seul et même article, le client peut être un peu perdu au début mais il peut au final les reconnaître comme étant identiques. Il s'agirait là d'une erreur, mais pas aussi grave que dans le scénario précédent.

Dans quel cas favoriser le rappel

Privilégiez le rappel si vous êtes plus préoccupé par le risque que les résultats de la transformation FindMatches ne parviennent pas à détecter une paire d'enregistrements qui correspondent réellement. Pour favoriser le rappel, choisissez une valeur de compris précision-rappel plus faible. Avec une valeur plus faible, la transformation FindMatches a besoin de moins de preuves pour décider qu'une paire d'enregistrements doivent correspondre. La transformation est réglée sur une tendance à indiquer que les enregistrements correspondent.

Cela peut, par exemple, être une priorité pour une organisation de sécurité. Supposons que vous établissez des correspondances entre des clients et une liste de fraudeurs connus, et il est important de déterminer si un client est un fraudeur. Vous utilisez FindMatches pour établir des correspondances entre la liste de fraudeurs et la liste de clients. Chaque fois que FindMatches détecte une correspondance entre les deux listes, un auditeur humain est affecté pour vérifier que la personne est effectivement un fraudeur. Il se peut que votre organisation préfère le rappel à la précision. En d'autres termes, vous préférez plutôt avoir des auditeurs qui vérifient et rejettent manuellement certains cas lorsque le client n'est pas un fraudeur que de ne pas parvenir à identifier qu'un client est, effectivement, sur la liste de fraudeurs.

Comment favoriser à la fois la précision et le rappel

Le meilleur moyen d'améliorer à la fois la précision et le rappel est d'étiqueter davantage de données. Au fur et à mesure que vous étiquetez plus de données, l'exactitude globale de la transformation FindMatches s'améliore, ce qui améliore à la fois la précision et le rappel. Néanmoins, même avec la transformation la plus précise possible, il demeure toujours une zone grise où vous devez essayer de favoriser la précision ou le rappel, ou choisir une valeur intermédiaire.

Choisir entre l'exactitude et le coût

Chaque transformation FindMatches contient un paramètre `accuracy-cost`. Vous pouvez utiliser ce paramètre pour spécifier l'un des éléments suivants :

- Si vous êtes plus préoccupé par le fait que la transformation indique précisément que deux enregistrements correspondent, vous devez mettre l'accent sur la précision.
- Si vous êtes plus préoccupé par le coût ou la vitesse d'exécution de la transformation, vous devez mettre l'accent sur la réduction des coûts.

Vous pouvez faire ce compromis sur AWS Glue console ou en utilisant AWS Glue opérations d'API d'apprentissage automatique.

Dans quel cas favoriser l'exactitude

Privilégiez la précision si vous êtes plus préoccupé par le risque que les résultats de `find matches` ne contiennent des correspondances. Pour favoriser l'exactitude, choisissez une valeur de compromis exactitude-coût plus élevée. Avec une valeur plus élevée, la transformation `FindMatches` a besoin de plus de temps pour effectuer une recherche plus approfondie afin de trouver des enregistrements qui correspondent correctement. Notez que ce paramètre ne réduit pas le risque d'appeler de manière erronée une correspondance une paire d'enregistrements non correspondants. La transformation est réglée sur une tendance à consacrer plus de temps à la recherche de correspondances.

Dans quel cas favoriser le coût

Privilégiez le coût si vous êtes plus préoccupé par le coût d'exécution de la transformation `find matches` et moins préoccupé par le nombre de correspondances trouvées. Pour favoriser le coût, choisissez une valeur de compromis exactitude-coût plus faible. Avec une valeur plus faible, la transformation `FindMatches` a besoin de moins de ressources pour son exécution. La transformation est réglée sur une tendance à rechercher moins de correspondances. Si le fait de favoriser la réduction des coûts produit des résultats acceptables, utilisez ce paramètre.

Comment favoriser à la fois l'exactitude et la réduction des coûts

Un temps machine supérieur est nécessaire pour examiner davantage de paires d'enregistrements afin de déterminer s'il peut s'agir de correspondances. Si vous souhaitez réduire les coûts sans réduire la qualité, voici quelques conseils :

- Éliminez dans votre source de données les enregistrements pour lesquels vous ne cherchez pas de correspondances.
- Éliminez dans votre source de données les colonnes qui sont de manière certaine inutiles à la prise d'une décision correspondance/non correspondance. Une bonne manière de déterminer cela consiste à éliminer les colonnes qui n'affectent en rien votre décision quant il s'agit de déterminer si un ensemble d'enregistrements sont « identiques ».

Estimation de la qualité des correspondances à l'aide des notes de confiance des correspondances

Les scores de confiance des correspondances fournissent une estimation de la qualité des correspondances trouvées `FindMatches` afin de faire la distinction entre les enregistrements correspondants dans lesquels le modèle d'apprentissage automatique est très sûr, incertain ou peu probable. Une note de confiance des correspondances sera comprise entre 0 et 1, alors

qu'une note plus élevée signifie une similitude plus élevée. L'examen des notes de confiance des correspondances vous permet de distinguer les clusters de correspondances pour lesquels le système est très confiant (que vous pouvez décider de fusionner), les clusters dont le système est incertain (que vous pouvez décider de faire vérifier par un humain) et les clusters que le système juge improbables (que vous pouvez décider de rejeter).

Vous voudrez peut-être ajuster vos données d'entraînement dans des situations où vous constatez une note de confiance des correspondances élevées, mais déterminez qu'il n'y a pas de correspondances, ou lorsque vous voyez une note faible, mais déterminez qu'il y a en fait des correspondances.

Les scores de confiance sont particulièrement utiles lorsqu'il existe des ensembles de données industriels de grande taille, pour lesquels il est impossible de revoir chaque FindMatches décision.

Les scores de confiance des matchs sont disponibles dans AWS Glue version 2.0 ou ultérieure.

Génération des notes de confiance des correspondances

Vous pouvez générer des notes de confiance des correspondances en définissant la valeur booléenne de `computeMatchConfidenceScores` sur `true` (VRAI) lorsque vous appelez l'API `FindMatches` ou `FindIncrementalMatches`.

AWS Glue ajoute un nouveau column `match_confidence_score` à la sortie.

Exemples de notation des correspondances

Prenons l'exemple des registres de correspondance suivant :

Note $\geq 0,9$

Résumé des registres correspondants :

primary_id	match_id	match_confidence_score
3281355037663	85899345947	0.9823658302132061
1546188247619	85899345947	0.9823658302132061

Détails :

city		raw_id	phone	source	website	poi_id	display_position		primary_name	locale_name	street1	street2	street3							
city	state	country	postal_code	street_in_one_line	primary_id	match_id	match_confidence_score													
[ae]	Jg	SD01	Cb	IFPPL1	[g]	43262681168	http://www.commerzbank.at		[yelp:aeJgSD01CbIFPPL1]g	geo:47.711590000,16.344820000	Commerzbank	Mattersburg	en_US	Hauptstr.	59	null	Forchtenstein	1	AT	7212
		Hauptstr.	59	[546188247619]	[85899345947]	0.98236583212061														
[uMhQk6v2]	Jg	ZN4NB1Xh-Q0	[43268747266]	yelp:http://www.commerzbank.at		[yelp:uMhQk6v2]Jg	ZN4NB1Xh-Q0	geo:47.787420000,16.455440000	Commerzbank	Mattersburg	en_US	Hauptstr.	9	null	null	Hirm	1	AT	7824	
		[91261355837663]	[85899345947]			0.98236583212061														

Dans cet exemple, nous pouvons voir que deux registres sont très similaires et partagent `display_position`, `primary_name`, et `street name`.

Note $\geq 0,8$ et note $< 0,9$

Résumé des registres correspondants :

primary_id	match_id	match_confidence_score
309237680432	85899345928	0.8309852373674638
3590592666790	85899345928	0.8309852373674638
343597390617	85899345928	0.8309852373674638
249108124906	85899345928	0.8309852373674638
463856477937	85899345928	0.8309852373674638

Détails :

primary_id	raw_id	phone	source	website	poi_id	display_position	primary_name	locale_name	street1	street2	street3	city	state	country	postal_code	street_in_one_line
[309237680432]	[3590592666790]	[343597390617]	[249108124906]	[463856477937]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]
[309237680432]	[3590592666790]	[343597390617]	[249108124906]	[463856477937]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]	[85899345928]

Dans cet exemple, nous pouvons voir que ces registres partagent le même `primary_name`, et `country`.

Note $\geq 0,6$ et note $< 0,7$

Résumé des registres correspondants :

primary_id	match_id	match_confidence_score
2164663519676	85899345930	0.6971099896480333
317827595278	85899345930	0.6971099896480333
472446424341	85899345930	0.6971099896480333
3118146262932	85899345930	0.6971099896480333
214748380804	85899345930	0.6971099896480333

Détails :

[illegible]

Dans cet exemple, nous pouvons voir que ces registres ne partagent que le même `primary_name`.

Pour plus d'informations, consultez :

- [Étape 5 : Ajouter et exécuter une tâche avec votre transformation Machine Learning](#)
- PySpark: [FindMatches classe](#)
- PySpark: [FindIncrementalMatches classe](#)
- Scala : [FindMatches classe](#)
- Scala : [FindIncrementalMatches classe](#)

Entraîner la transformation à trouver des correspondances

Il est nécessaire d'entraîner chaque transformation `FindMatches` à déterminer ce qui est une correspondance et ce qui ne l'est pas. Vous enseignez votre transformation en ajoutant des étiquettes à un fichier et en téléchargeant vos choix vers AWS Glue.

Vous pouvez orchestrer cet étiquetage sur le AWS Glue console ou en utilisant le AWS Glue opérations d'API d'apprentissage automatique.

Combien de fois dois-je ajouter des étiquettes ? De combien d'étiquettes ai-je besoin ?

Les réponses à ces questions dépendent essentiellement de vous. Vous devez évaluer si FindMatches offre le niveau d'exactitude dont vous avez besoin et si vous pensez qu'un effort d'étiquetage supplémentaire est utile pour vous. La meilleure façon d'en décider est d'examiner les métriques « Précision », « Rappel » et « Zone située sous la courbe de rappel de précision » que vous pouvez générer lorsque vous choisissez Estimer la qualité sur le AWS Glue console. Une fois que vous avez étiqueté plusieurs ensembles de tâches, réexécutez ces métriques et vérifiez si elles présentent des améliorations. Si, après l'étiquetage de quelques ensembles de tâches, vous ne constatez pas une amélioration au niveau de la métrique concernée, il est vraisemblable que la qualité de la transformation a atteint son niveau maximum.

Pourquoi les étiquettes Vrai positif et Vrai négatif sont-elles nécessaires ?

La transformation `FindMatches` nécessite à la fois des exemples positifs et négatifs pour vous permettre d'enseigner ce que vous estimez être une correspondance. Si vous étiquetez des données de formation générées par `FindMatches` (par exemple, à l'aide de l'option `I do not have labels` (Je ne dispose pas d'étiquettes), `FindMatches` essaie de générer un ensemble d'« ID d'ensemble d'étiquettes » pour vous. Au sein de chaque tâche, vous donnez la même « étiquette » à certains enregistrements et des « étiquettes » différentes à d'autres enregistrements. En d'autres termes, les tâches ne sont généralement pas toutes identiques ou toutes différentes (mais c'est normal si une tâche particulière est entièrement « identique » ou entièrement « non identique »).

Si vous entraînez votre transformation `FindMatches` à l'aide de l'option `Upload labels from S3` (Télécharger des étiquettes de S3), essayez d'inclure à la fois des exemples d'enregistrements correspondants et non correspondants. Il est acceptable d'avoir un seul type. Ces étiquettes vous aident à créer une transformation `FindMatches` plus exacte, mais vous devez quand-même étiqueter certains enregistrements que vous générez à l'aide de l'option `Generate labeling file` (Générer un fichier d'étiquetage).

Comment puis-je m'assurer que la transformation fasse exactement ce que je lui ai enseigné ?

La transformation `FindMatches` apprend à partir des étiquettes que vous fournissez, elle peut donc générer des paires d'enregistrements qui ne respectent pas les étiquettes fournies. Pour garantir que la `FindMatches` transformation respecte vos étiquettes, sélectionnez « `EnforceProvidedLabels` in `FindMatchesParameter` ».

Quelles techniques puis-je utiliser lorsqu'une transformation ML identifie des éléments en tant que correspondances alors qu'elles n'en sont pas vraiment ?

Vous pouvez utiliser les techniques suivantes :

- Définir `precisionRecallTradeoff` sur une valeur plus élevée. Cela peut se traduire par la production d'un nombre de correspondances inférieur, mais cela peut également permettre de fractionner votre gros cluster lorsqu'il atteint une valeur suffisamment élevée.
- Prenez les lignes de sortie correspondant aux résultats incorrects et reformatez-les en tant qu'ensemble d'étiquetage (en retirant la colonne `match_id` et en ajoutant une colonne `labeling_set_id` et `label`). Si nécessaire, fractionnez (subdivisez) en plusieurs ensembles d'étiquetage afin de vous assurer que l'étiqueteur peut continuer en gardant chaque étiquetage à l'esprit tout en affectant des étiquettes. Ensuite, étiquetez correctement les ensembles correspondants, puis chargez le fichier d'étiquettes et ajoutez-le à vos étiquettes existantes. Cela peut suffisamment entraîner votre transformateur à ce qu'il doit rechercher pour comprendre le modèle.

- (Avancé) Enfin, examinez ces données pour voir si vous pouvez détecter un modèle que le système n'a pas remarqué. Prétraitez ces données à l'aide de la norme AWS Glue fonctions permettant de normaliser les données. Mettez en évidence ce sur quoi l'algorithme doit se baser pour apprendre en séparant les données que vous jugez différemment importantes dans leurs propres colonnes. Vous pouvez aussi créer des colonnes combinées à partir de colonnes contenant des données connexes.

Travailler avec l'apprentissage automatique transforme

Vous pouvez l'utiliser AWS Glue pour créer des transformations d'apprentissage automatique personnalisées qui peuvent être utilisées pour nettoyer vos données. Vous pouvez utiliser ces transformations lorsque vous créez une tâche sur la console AWS Glue .

Pour de plus amples informations sur la création d'une transformation Machine Learning, veuillez consulter [Record correspondant à AWS Lake Formation FindMatches](#).

Rubriques

- [Propriétés de transformation](#)
- [Ajout et modification de transformations Machine Learning](#)
- [Affichage des détails d'une transformation](#)
- [Entraîner les transformations à l'aide d'étiquettes](#)

Propriétés de transformation

Pour consulter une transformation d'apprentissage automatique existante, connectez-vous au AWS Management Console, puis ouvrez AWS Glue console à <https://console.aws.amazon.com/glue/>. Dans le volet de navigation, sous Intégration des données et ETL, choisissez Outils de classification des données > Correspondance des enregistrements.

Les propriétés de chaque transformation :

Nom de transformation

Nom unique donné à la transformation lors de sa création.

ID

Identifiant unique de la transformation.

Nombre d'étiquettes

Le nombre d'étiquettes dans le fichier d'étiquetage qui a été fourni pour aider à entraîner la transformation.

Statut

Indique si la transformation a le statut Ready (Prêt) ou Needs teaching (Entraînement nécessaire). Pour qu'une transformation machine learning puisse s'exécuter dans une tâche, elle doit avoir le statut Ready (Prêt).

Créé

Date de création de la transformation.

Modifié

Date de la dernière mise à jour de la transformation.

Description

Description fournie pour la transformation, le cas échéant.

AWS Glue version

La version de AWS Glue utilisé.

ID d'exécution

Nom unique donné à la transformation lors de sa création.

Type de tâche

Type de transformation Machine Learning ; par exemple, Find matching records (Rechercher des enregistrements correspondants).

Statut

Indique le statut de l'exécution de la tâche. Les statuts possibles incluent :

- Démarrage en cours
- En cours d'exécution
- Arrêt en cours
- Arrêté(e)
- Réussi

- Échec
- Expiration

Erreur

Si le statut est Échec, un message d'erreur indiquant la raison de l'échec s'affiche.

Ajout et modification de transformations Machine Learning

Vous pouvez afficher, supprimer, configurer et enseigner, ou ajuster une transformation sur AWS Glue console. Cochez la case en regard de la transformation dans la liste, choisissez Action, puis choisissez l'action que vous souhaitez effectuer.

Création d'une nouvelle transformation ML

Pour ajouter une nouvelle transformation machine learning, choisissez Créer une transformation. Suivez les instructions fournies dans l'assistant Ajouter une tâche. Pour de plus amples informations, veuillez consulter [Record correspondant à AWS Lake Formation FindMatches](#).

Étape 1. Définissez les propriétés de la transformation.

1. Saisissez un nom et une description de la tâche (facultatif).
2. Définissez éventuellement la configuration de sécurité. Consultez [Utilisation du chiffrement des données avec les transformations machine learning](#).
3. Définissez éventuellement les paramètres d'exécution des tâches. Les paramètres d'exécution des tâches vous permettent de personnaliser le mode d'exécution de la tâche. Sélectionnez le type de travailleur, le nombre de travailleurs, le délai d'expiration de la tâche (en minutes), le nombre de nouvelles tentatives et AWS Glue version.
4. Vous pouvez éventuellement définir des balises. Les tags sont des libellés que vous pouvez attribuer à une AWS ressource. Chaque balise est constituée d'une clé et d'une valeur facultative. Les balises peuvent être utilisées pour rechercher et filtrer vos ressources ou pour suivre vos AWS coûts.

Étape 2. Choisissez la table et la clé primaire.

1. Cliquez sur l'onglet AWS Glue Base de données et table du catalogue.
2. Choisissez une clé primaire dans le tableau sélectionné. La colonne de clé primaire contient généralement un identifiant unique pour chaque enregistrement de la source de données.

Étape 3. Sélectionnez les options de réglage.

1. Pour Rappel ou précision, choisissez la valeur de réglage pour ajuster la transformation afin de favoriser le rappel ou la précision. Par défaut, Équilibré est sélectionné, mais vous pouvez choisir de privilégier le rappel ou la précision, ou choisir Personnalisé et saisir une valeur comprise entre 0,0 et 1,0 (inclus).
2. Pour Réduire le coût ou la précision, choisissez la valeur de réglage qui favorise la réduction des coûts ou de la précision, ou choisissez Personnalisé et saisissez une valeur comprise entre 0,0 et 1,0 (inclus).
3. Pour Application de la correspondance, choisissez Forcer la sortie à correspondre aux étiquettes si vous souhaitez entraîner la transformation ML en forçant la sortie à correspondre aux étiquettes utilisées.

Étape 4 : Vérifiez et créez.

1. Passez en revue les options des étapes 1 à 3.
2. Choisissez Modifier pour chaque étape qui doit être modifiée. Choisissez Créer une transformation pour terminer l'assistant de création de transformation.

Utilisation du chiffrement des données avec les transformations machine learning

Lorsque vous ajoutez une transformation de machine learning à AWS Glue, vous pouvez éventuellement spécifier une configuration de sécurité associée à la source de données ou à la cible de données. Si le compartiment Amazon S3 utilisé pour stocker les données est chiffré avec une configuration de sécurité, spécifiez la même configuration de sécurité lors de la création de la transformation.

Vous pouvez également choisir d'utiliser le chiffrement côté serveur avec AWS KMS (SSE-KMS) pour chiffrer le modèle et les étiquettes afin d'empêcher des personnes non autorisées de l'inspecter. Si vous choisissez cette option, vous êtes invité à choisir le AWS KMS key nom, ou vous pouvez choisir Enter a key ARN. Si vous choisissez de saisir l'ARN de la clé KMS, un deuxième champ apparaît dans lequel vous pouvez saisir l'ARN de la clé KMS.

Note

Actuellement, les transformations ML utilisant une clé de chiffrement personnalisée ne sont pas prises en charge dans les régions suivantes :

- Asie-Pacifique (Osaka) - ap-northeast-3

Affichage des détails d'une transformation

Affichage des propriétés de transformation

La page Propriété de transformation inclut les attributs de votre transformation. Il affiche les détails relatifs à la définition de transformation, y compris les éléments suivants :

- Transform name (Nom de la transformation) indique le nom de la transformation.
- Type répertorie le type de la transformation.
- Status (État) affiche si la transformation est prête à être utilisée dans un script ou une tâche.
- Force output to match labels (Forcer la sortie pour faire correspondre les étiquettes) affiche si la transformation force la sortie afin qu'elle fasse correspondre les étiquettes fournies par l'utilisateur.
- La version Spark est liée à AWS Glue version que vous avez choisie dans les propriétés d'exécution de la tâche lors de l'ajout de la transformation. AWS Glue Les versions 1.0 et Spark 2.4 sont recommandées à la plupart des clients. Pour plus d'informations, consultez [AWS Glue Des versions](#).

Onglets Historique, Estimation de la qualité et Balises

Les détails d'une transformation incluent les informations que vous avez définies lors de la création de cette transformation. Pour afficher les détails d'une transformation, sélectionnez la transformation dans la liste Machine learning transforms (Transformations Machine learning), puis consultez les informations sur les onglets suivants :

- Historique
- Estimation de la qualité
- Balises

Historique

L'onglet History (Historique) affiche l'historique d'exécution de votre tâche de transformation. Plusieurs types de tâches sont exécutées pour entraîner une transformation. Pour chaque tâche, les métriques d'exécution sont les suivantes :

- Run ID est un identifiant créé par AWS Glue pour chaque exécution de cette tâche.
- Task type (Type de tâche) affiche le type de l'exécution de tâche.
- Run status (Statut d'exécution) indique la réussite de chaque tâche répertoriée avec l'exécution la plus récente en haut de la liste.
- Error (Erreur) affiche les détails d'un message d'erreur si l'exécution a échoué..
- Start time (Heure de début) indique la date et l'heure (heure locale) auxquelles la tâche a démarré.
- Heure de fin indique la date et l'heure (heure locale) auxquelles la tâche s'est terminée.
- Logs (Journaux) fournit des liens vers les journaux écrits sur stdout pour cette exécution de tâche.

Le lien Logs permet d'accéder à Amazon CloudWatch Logs. Vous pouvez y consulter les détails relatifs aux tables créées dans le AWS Glue Data Catalog et aux éventuelles erreurs rencontrées. Vous pouvez gérer la période de conservation des journaux sur la CloudWatch console. La conservation des journaux par défaut est `Never Expire`. Pour plus d'informations sur la modification de la période de conservation, consultez la section [Conservation des données du journal des modifications dans CloudWatch les journaux](#) dans le guide de l'utilisateur Amazon CloudWatch Logs.

- Fichier d'étiquettes fournit un lien vers Amazon S3 pour un fichier d'étiquetage généré.

Estimation de la qualité

L'onglet Estimate quality (Estimation de la qualité) affiche les métriques que vous utilisez pour mesurer la qualité de la transformation. Les estimations sont calculées en comparant les prédictions de correspondance de transformation à l'aide d'un sous-ensemble de vos données étiquetées par rapport aux étiquettes que vous avez fournies. Ces estimations sont approximatives. Vous pouvez appeler une tâche Estimate quality (Estimation de la qualité) exécutée à partir de cet onglet.

L'onglet Estimate quality (Estimation de la qualité) affiche les métriques de la dernière estimation de la qualité, y compris les propriétés suivantes :

- Area under the Precision-Recall curve (Zone sous la courbe de précision-rappel est un nombre unique qui estime la limite supérieure de la qualité globale de la transformation. Il est indépendant du choix effectué pour le paramètre de précision-rappel. Des valeurs plus élevées indiquent que vous avez un compromis précision-rappel plus attractif.
- Precision (Précision) évalue la fréquence à laquelle la transformation est correcte lorsqu'elle prédit une correspondance.

- Recall upper limit (Limite supérieure de rappel) évalue, pour une correspondance réelle, la fréquence à laquelle la transformation prédit la correspondance.
- F1 évalue la précision de la transformation comprise entre 0 et 1, où 1 est la meilleure précision. Pour plus d'informations, consultez la page Wikipedia relative au [score F1](#).
- La table Column importance (Importance de la colonne) affiche les noms de colonnes et le score d'importance de chaque colonne. L'importance des colonnes vous aide à comprendre comment elles contribuent à votre modèle, en identifiant les colonnes de vos enregistrements qui sont le plus utilisées pour effectuer la correspondance. Ces données peuvent vous inciter à ajouter ou à modifier votre jeu d'étiquettes pour augmenter ou réduire l'importance des colonnes.

La colonne Importance fournit un score numérique pour chaque colonne, sous la forme d'une décimale ne dépassant pas 1,0.

Pour de plus amples informations sur la compréhension des estimations de qualité et de la qualité réelle, veuillez consulter [Estimations de la qualité par rapport à la end-to-end \(vraie\) qualité](#).

Pour de plus amples informations sur le réglage de votre transformation, veuillez consulter [Le réglage de l'apprentissage automatique se transforme AWS Glue](#).

Estimations de la qualité par rapport à la end-to-end (vraie) qualité

AWS Glue estime la qualité de votre transformation en présentant le modèle interne d'apprentissage automatique avec un certain nombre de paires d'enregistrements pour lesquelles vous avez fourni des étiquettes correspondantes mais que le modèle n'avait jamais vues auparavant. Ces estimations de qualité sont une fonction de la qualité du modèle appris par la machine (qui est influencé par le nombre d'enregistrements que vous étiquetez pour « entraîner » la transformation). Le rappel end-to-end, ou véritable rappel (qui n'est pas automatiquement calculé par le `ML transform`) est également influencé par le mécanisme de `ML transform` filtrage qui propose une grande variété de correspondances possibles avec le modèle appris par machine.

Vous pouvez régler cette méthode de filtrage essentiellement en spécifiant la valeur de réglage Réduction coût-précision. À mesure que la valeur de réglage se rapproche de Précision, le système effectue une recherche plus approfondie et plus coûteuse des paires d'enregistrements qui pourraient être des correspondances. Un plus grand nombre de paires d'enregistrements sont introduites dans votre modèle d'apprentissage automatique, et votre `ML transform` rappel réel se rapproche de la métrique de rappel estimée. end-to-end Par conséquent, les modifications de la end-to-end qualité de vos correspondances résultant de modifications du compromis coût/précision de vos correspondances ne seront généralement pas prises en compte dans l'estimation de la qualité.

Balises

Les tags sont des libellés que vous pouvez attribuer à une AWS ressource. Chaque balise est constituée d'une clé et d'une valeur facultative. Les balises peuvent être utilisées pour rechercher et filtrer vos ressources ou pour suivre vos AWS coûts.

Entraîner les transformations à l'aide d'étiquettes

Vous pouvez entraîner votre transformation ML à l'aide d'étiquettes (exemples) en choisissant Entraîner une transformation sur la page de détails de la transformation ML. Lorsque vous entraînez votre algorithme de machine learning en fournissant des exemples (appelés étiquettes), vous pouvez choisir les étiquettes existantes à utiliser ou créer un fichier d'étiquetage.

Teach the transform using labels

Labeling

Teach your machine learning algorithms by providing examples, called labels. For your transform, provide examples of matching and nonmatching records.

☒ I do not have labels

☐ I have labels

► How to label

Generate labeling file

AWS Glue extracts records from your source data and suggests potential matching records. The file will contain approximately 100 data samples for you to work with. You can download the file once it has been generated.

S3 path to store the generated label file

🔍 s3://bucket/prefix/object

View 

Browse S3

Generate labeling file

Download labeling file

Upload labels from S3

The completed labeling file must be in the correct format and in Amazon S3.

S3 path where the label file is stored

🔍 s3://bucket/prefix/object

View 

Browse S3

Existing labels

☒ Append to my existing labels

☐ Overwrite my existing labels

Upload labeling file from S3

- Étiquetage : si vous avez des étiquettes, choisissez J'ai des étiquettes. Si vous n'avez pas d'étiquettes, vous pouvez toujours passer à l'étape suivante pour générer un fichier d'étiquettes.
- Générer un fichier d'étiquetage — AWS Glue extrait des enregistrements de vos données sources et suggère des enregistrements correspondants potentiels. Vous choisissez le compartiment

Amazon S3 pour stocker le fichier d'étiquette généré. Choisissez Générer un fichier d'étiquetage pour démarrer le processus. Lorsque vous avez terminé, choisissez Télécharger le fichier d'étiquetage. Le fichier téléchargé comportera une colonne pour les étiquettes dans laquelle vous pourrez remplir les étiquettes.

- Charger des étiquettes depuis Amazon S3 : choisissez le fichier d'étiquetage complet dans le compartiment Amazon S3 dans lequel le fichier d'étiquetage est stocké. Choisissez ensuite d'ajouter les étiquettes à vos étiquettes existantes ou de les remplacer. Choisissez Charger le fichier d'étiquetage depuis Amazon S3.

Didacticiel : Création d'une transformation de Machine Learning avec AWS Glue

Ce didacticiel vous guide tout au long des actions de création et de gestion d'une transformation Machine Learning (ML) à l'aide de AWS Glue. Avant d'utiliser ce didacticiel, vous devez être familiarisé avec le AWS Glue console pour ajouter des robots d'exploration et des tâches et modifier des scripts. Vous devez également être familiarisé avec la recherche et le téléchargement de fichiers sur la console Amazon Simple Storage Service (Amazon S3).

Dans cet exemple, vous créez une FindMatches transformation pour rechercher des enregistrements correspondants, lui apprendre à identifier les enregistrements correspondants et non correspondants, et l'utiliser dans un AWS Glue travail. Le AWS Glue job écrit un nouveau fichier Amazon S3 avec une colonne supplémentaire nommée `match_id`.

Les données source utilisées par ce tutoriel sont un fichier nommé `dblp_acm_records.csv`. Ce fichier est une version modifiée de publications universitaires (DBLP et ACM) disponibles à partir de l'ensemble de données DBLP ACM [d'origine](#). Le fichier `dblp_acm_records.csv` est un fichier CSV (valeurs séparées par une virgule) au format UTF-8 sans marque d'ordre d'octet (BOM).

Un second fichier, `dblp_acm_labels.csv`, est un exemple de fichier d'étiquetage qui contient des enregistrements correspondants et non correspondants utilisés pour entraîner la transformation dans le cadre du didacticiel.

Rubriques

- [Étape 1 : Analyse des données source](#)
- [Étape 2 : Ajouter une transformation de Machine Learning](#)
- [Étape 3 : Entraîner votre transformation Machine Learning](#)
- [Étape 4 : Estimer la qualité de votre transformation Machine Learning](#)

- [Étape 5 : Ajouter et exécuter une tâche avec votre transformation Machine Learning](#)
- [Étape 6 : vérifier les données de sortie d'Amazon S3](#)

Étape 1 : Analyse des données source

Tout d'abord, analysez le fichier CSV source Amazon S3 pour créer une table de métadonnées correspondante dans Data Catalog.

Important

Pour indiquer à le crawler de créer une table pour seulement le fichier CSV, stockez les données source CSV dans un autre dossier Amazon S3 à partir d'autres fichiers.

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sélectionnez Crawlers, Ajouter un crawler.
3. Suivez les instructions de l'assistant pour créer et exécuter un crawler nommé `demo-crawl-dblp-acm` avec une sortie dans une base de données `demo-db-dblp-acm`. Lorsque vous exécutez l'assistant, créez la base de données `demo-db-dblp-acm` si elle n'existe pas déjà. Choisissez un chemin d'inclusion Amazon S3 vers les échantillons de données dans la AWS région actuelle. Par exemple, pour `us-east-1`, le chemin d'inclusion Amazon S3 pour le fichier source est `s3://ml-transforms-public-datasets-us-east-1/dblp-acm/records/dblp_acm_records.csv`.

Si l'opération aboutit, le crawler crée la table `dblp_acm_records_csv` avec les colonnes suivantes : `id`, `title`, `authors`, `venue`, `year` et `source`.

Étape 2 : Ajouter une transformation de Machine Learning

Ensuite, ajoutez une transformation de Machine Learning basée sur le schéma de votre table source de données créée par le crawler nommé `demo-crawl-dblp-acm`.

1. Sur le AWS Glue console, dans le volet de navigation sous Intégration des données et ETL, choisissez Outils de classification des données > Record Matching, puis Ajouter une transformation. Suivez les instructions de l'assistant pour créer une transformation `Find matches` avec les propriétés suivantes.

- a. Pour Transform name (Nom de transformation), entrez **demo-xform-dblp-acm**. Il s'agit du nom de la transformation qui est utilisée pour rechercher des correspondances dans les données source.
 - b. Pour le rôle IAM, choisissez un rôle IAM autorisé à accéder aux données sources, au fichier d'étiquetage d'Amazon S3 et AWS Glue Opérations d'API. Pour plus d'informations, voir [Créer un rôle IAM pour AWS Glue](#) dans le Manuel du développeur AWS Glue .
 - c. Pour Source de données, choisissez la table nommée `dblp_acm_records_csv` dans la base de données. `demo-db-dblp-acm`
 - d. Pour Primary key (Clé primaire), choisissez la colonne de clé primaire pour la table, `id`.
2. Dans l'assistant, choisissez, choisissez Finish (Terminer) et revenez à la liste ML transforms (Transformations ML).

Étape 3 : Entraîner votre transformation Machine Learning

Ensuite, vous entraînez votre transformation Machine Learning à l'aide du fichier d'étiquetage de l'exemple de didacticiel.

Vous ne pouvez pas utiliser une transformation Machine Language dans une tâche d'extraction, de transformation et de chargement (ETL) tant que son statut n'est pas Ready for use (Prêt pour utilisation). Pour que votre transformation soit prête, vous devez l'entraîner à identifier les enregistrements correspondants et non correspondants en fournissant des exemples d'enregistrements correspondants et non correspondants. Pour entraîner votre transformation, vous pouvez Générer un fichier d'étiquettes, ajouter des étiquettes, puis Télécharger le fichier d'étiquettes. Dans ce didacticiel, vous pouvez utiliser l'exemple de fichier d'étiquetage nommé `dblp_acm_labels.csv`. Pour plus d'informations sur le processus d'étiquetage, veuillez consulter [Étiquetage](#).

1. Sur le AWS Glue console, dans le volet de navigation, choisissez Record Matching.
2. Choisissez la transformation `demo-xform-dblp-acm`, puis choisissez Action, Teach (Entraîner). Suivez les instructions de l'assistant pour entraîner votre transformation Find matches.
3. Sur la page des propriétés de transformation, choisissez I have labels (Je dispose d'étiquettes). Choisissez un chemin Amazon S3 vers l'exemple de fichier d'étiquetage dans la AWS région actuelle. Par exemple, pour `us-east-1`, chargez le fichier d'étiquetage fourni à partir du chemin Amazon S3 `s3://ml-transforms-public-datasets-us-east-1/dblp-acm/labels/`

`dblp_acm_labels.csv` avec l'option de remplacement des étiquettes existantes. Le fichier d'étiquetage doit se trouver dans Amazon S3, dans la même région que le AWS Glue console.

Lorsque vous chargez un fichier d'étiquetage, une tâche est lancée dans AWS Glue pour ajouter ou remplacer les étiquettes utilisées pour enseigner à la transformation comment traiter la source de données.

4. Sur la dernière page de l'assistant, choisissez Terminer, puis revenez à la liste Transformations Machine Learning.

Étape 4 : Estimer la qualité de votre transformation Machine Learning

Ensuite, vous pouvez estimer la qualité de votre transformation Machine Learning. La qualité dépend de la quantité d'étiquetage que vous avez effectuée. Pour en savoir plus sur l'estimation de la qualité, consulter [Estimation de la qualité](#).

1. Sur le AWS Glue console, dans le volet de navigation sous Intégration des données et ETL, choisissez Outils de classification des données > Record Matching.
2. Choisissez la transformation `demo-xform-dblp-acm`, puis choisissez l'onglet Estimate quality (Estimation de la qualité). Cet onglet affiche les estimations de qualité actuelles, le cas échéant, pour la transformation.
3. Choisissez Estimation de la qualité pour démarrer une tâche permettant d'estimer la qualité de la transformation. La précision de l'estimation de la qualité est basée sur l'étiquetage des données source.
4. Accédez à l'onglet History (Historique). Dans ce panneau, les exécutions de tâche sont répertoriées pour la transformation, y compris la tâche Estimation de la qualité. Pour plus de détails sur l'exécution, choisissez Journaux. Vérifiez que le statut d'exécution est Réussite lorsqu'elle se termine.

Étape 5 : Ajouter et exécuter une tâche avec votre transformation Machine Learning

Au cours de cette étape, vous utilisez votre transformation d'apprentissage automatique pour ajouter et exécuter une tâche dans AWS Glue. Lorsque la transformation `demo-xform-dblp-acm` est prête à être utilisée, vous pouvez l'utiliser dans une tâche ETL.

1. Sur le AWS Glue console, dans le volet de navigation, choisissez Jobs.
2. Choisissez Ajouter une tâche, et suivez les étapes de l'assistant pour créer une tâche ETL Spark avec un script généré. Choisissez les valeurs de propriété suivantes pour votre transformation :

- a. Pour Nom, choisissez l'exemple de tâche dans ce didacticiel, demo-etl-dblp-acm.
 - b. Pour le rôle IAM, choisissez un rôle IAM autorisé à accéder aux données sources, au fichier d'étiquetage d'Amazon S3 et AWS Glue Opérations d'API. Pour plus d'informations, voir [Créer un rôle IAM pour AWS Glue](#) dans le Manuel du développeur AWS Glue .
 - c. Pour Langage ETL, choisissez Scala. Il s'agit du langage de programmation dans le script ETL.
 - d. Pour le nom du fichier de script, sélectionnez demo-etl-dblp-acm. Il s'agit du nom de fichier du script Scala (identique au nom de la tâche).
 - e. Pour Data source (Source de données), choisissez dblp_acm_records_csv. La source de données que vous choisissez doit correspondre au schéma de source de données de la transformation Machine Learning.
 - f. Pour Type de transformation, choisissez Rechercher des enregistrements correspondants pour créer une tâche à l'aide d'une transformation Machine Learning.
 - g. Désactivez Enlever les enregistrements en double. Vous ne souhaitez pas retirer les enregistrements en double car les enregistrements de sortie écrits comportent un champ match_id supplémentaire ajouté.
 - h. Pour Transform demo-xform-dblp-acm, choisissez la transformation d'apprentissage automatique utilisée par la tâche.
 - i. Pour Créer des tables dans votre cible de données, choisissez de créer des tables avec les propriétés suivantes :
 - Type de magasin de données — **Amazon S3**
 - Format – **CSV**
 - Type de compression – **None**
 - Chemin cible : chemin Amazon S3 où est écrite la sortie de la tâche (dans la AWS région de console actuelle)
3. Choisissez Enregistrer la tâche et modifier le script pour afficher la page de l'éditeur de script.
 4. Modifiez le script pour ajouter une instruction qui entraîne l'écriture de la sortie de tâche du chemin d'accès cible dans un seul fichier de partition. Ajoutez cette instruction immédiatement après l'instruction qui exécute la transformation FindMatches. L'instruction est similaire à ce qui suit.

```
val single_partition = findmatches1.repartition(1)
```


Vous devez modifier l'instruction `.writeDynamicFrame(findmatches1)` pour écrire la sortie en tant que `.writeDynamicFrame(single_partition)`.

5. Une fois que vous avez modifié le script, cliquez sur Enregistrer. Le script modifié ressemble au code qui suit, mais personnalisé pour votre environnement.

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.ml.FindMatches
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    // @params: [JOB_NAME]
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
    // @type: DataSource
    // @args: [database = "demo-db-dblp-acm", table_name = "dblp_acm_records_csv",
transformation_ctx = "datasource0"]
    // @return: datasource0
    // @inputs: []
    val datasource0 = glueContext.getCatalogSource(database = "demo-db-dblp-acm",
tableName = "dblp_acm_records_csv", redshiftTmpDir = "", transformationContext =
"datasource0").getDynamicFrame()
    // @type: FindMatches
    // @args: [transformId = "tfm-123456789012", emitFusion = false,
survivorComparisonField = "<primary_id>", transformation_ctx = "findmatches1"]
    // @return: findmatches1
    // @inputs: [frame = datasource0]
    val findmatches1 = FindMatches.apply(frame = datasource0, transformId
= "tfm-123456789012", transformationContext = "findmatches1",
computeMatchConfidenceScores = true)

    // Repartition the previous DynamicFrame into a single partition.
    val single_partition = findmatches1.repartition(1)
  }
}
```

```
// @type: DataSink
// @args: [connection_type = "s3", connection_options = {"path": "s3://aws-
glue-ml-transforms-data/sal"}, format = "csv", transformation_ctx = "datasink2"]
// @return: datasink2
// @inputs: [frame = findmatches1]
val datasink2 = glueContext.getSinkWithFormat(connectionType =
"s3", options = JsonOptions("""{"path": "s3://aws-glue-ml-transforms-
data/sal"}"""), transformationContext = "datasink2", format =
"csv").writeDynamicFrame(single_partition)
Job.commit()
}
}
```

6. Appuyez sur Exécuter la tâche) pour démarrer l'exécution de la tâche. Vérifiez le statut de la tâche dans la liste des tâches. Une fois la tâche terminée, dans l'onglet Transformation ML, Historique, une nouvelle ligne exécution ID de type Tâche ETL est ajoutée.
7. Accédez à l'onglet Jobs (Tâches), Historique. Dans ce panneau, les exécutions de tâches sont répertoriées. Pour plus de détails sur l'exécution, choisissez Journaux. Vérifiez que le statut d'exécution est Réussite lorsqu'elle se termine.

Étape 6 : vérifier les données de sortie d'Amazon S3

Au cours de cette étape, vous vérifiez la sortie de la tâche exécutée dans le compartiment Amazon S3 que vous avez choisi lors de l'ajout à la tâche. Vous pouvez télécharger le fichier de sortie sur votre machine locale et vérifier que les enregistrements correspondants ont été identifiés.

1. Ouvrez la console Amazon S3 à l'adresse <https://console.aws.amazon.com/s3/>.
2. Téléchargez le fichier de sortie cible de la tâche demo-etl-dblp-acm. Ouvrez le fichier dans une application de feuille de calcul (vous devrez peut-être ajouter une extension de fichier .csv pour que le fichier s'ouvre correctement).

L'image suivante montre un extrait de la sortie dans Microsoft Excel.

	B	C	D	E	F	G	H	I
	title	authors	venue	year	source	primary_id	match_id	match_confidence_score
1	Semantic Integration of Environmental Models for Application to Global Information S	D. Scott Mackay	SIGMOD Record	1999	DBLP	3092	0	0.830985237
2	Semantic integration of environmental models for application to global information s	D. Scott Mackay	ACM SIGMOD Recor	1999	ACM	3590	0	0.830985237
3	Estimation of Query-Result Distribution and Its Application in Parallel-Join Load	Balan Viswanath Poosala, Yannis E. I	VLDB	1996	DBLP	3435	1	0.801848258
4	Estimation of Query-Result Distribution and Its Application in Parallel-Join Load	Balan Viswanath Poosala, Yannis E. I	Very Large Data Bas	1996	ACM	2491	1	0.801848258
5	Incremental Maintenance for Non-Distributive Aggregate Functions	Themistoklis Palpanas, Richar	VLDB	2002	DBLP	4638	2	0.697109993
6	Cost-based Selection of Path Expression Processing Algorithms in Object-Oriented Da	Zhao-Hui Tang, Georges Gardin	VLDB	1996	DBLP	3768	3	0.791241276
7	Cost-based Selection of Path Expression Processing Algorithms in Object-Oriented Da	Georges Gardin, Jean-Robert	Very Large Data Bas	1996	ACM	5926	3	0.791241276
8	Benchmarking Spatial Join Operations with Spatial Output	Erik G. Hoel, Hanan Samet	Very Large Data Bas	1995	ACM	9739	4	0.723535024
9	Benchmarking Spatial Join Operations with Spatial Output	Erik G. Hoel, Hanan Samet	VLDB	1995	DBLP	8124	4	0.723535024
10	Efficient geometry-based similarity search of 3D spatial databases	Daniel A. Keim	International Confe	1999	ACM	5647	5	0.786350237
11	Efficient Geometry-based Similarity Search of 3D Spatial Databases	Daniel A. Keim	SIGMOD Conference	1999	DBLP	3432	5	0.786350237
12	Mining the World Wide Web: An Information Search Approach - Book Review	Aris M. Oukel	SIGMOD Record	2002	DBLP	6790	6	0.697109993
13	Enhanced Abstract Data Types in Object-Relational Databases	Praveen Seshadri	VLDB J.	1998	DBLP	3617	7	0.827350237
14	Enhanced abstract data types in object-relational databases	Praveen Seshadri	The VLDB Journal &	1998	ACM	4906	7	0.827350237
15	Report on DART '96: Databases: Active and Real-Time (Concepts meet Practice)	Nandit Soparkar, Krithi Ramani	SIGMOD Record	1997	DBLP	7937	8	0.708350237
16	Report on DART '96: databases: active and real-time (concepts meet practice)	Krithi Ramamritham, Nandit S	ACM SIGMOD Recor	1997	ACM	8193	8	0.708350237
17	UnISOQL's next-generation object-relational database management system	Albert D'Andrea, Phil Janus	ACM SIGMOD Recor	1996	ACM	8491	9	0.818340237
18	UnISOQL's Next-Generation Object-Relational Database Management System	Phil Janus, Albert D'Andrea	SIGMOD Record	1996	DBLP	4869	9	0.818340237

La source de données et le fichier cible comportent tous deux 4 911 enregistrements. Toutefois, la transformation `Find matches` ajoute une autre colonne nommée `match_id` pour identifier les enregistrements correspondants dans la sortie. Les lignes avec le même `match_id` sont considérées comme des enregistrements correspondants. Le `match_confidence_score` est un nombre compris entre 0 et 1 qui fournit une estimation de la qualité des correspondances trouvées par `Find matches`.

3. Triez le fichier de sortie par `match_id` afin de voir facilement les enregistrements qui sont des correspondances. Comparez les valeurs des autres colonnes pour voir si les résultats de la transformation `Find matches` vous conviennent. Si ce n'est pas le cas, vous pouvez continuer à entraîner la transformation en ajoutant d'autres étiquettes.

Vous pouvez également trier le fichier sur un autre champ, par exemple `title`, pour voir si les enregistrements avec des titres similaires ont le même `match_id`.

Recherche de correspondances progressives

La fonction Recherche de correspondances vous permet d'identifier les registres en double ou correspondants dans votre jeu de données, même lorsque les registres n'ont pas un identifiant unique commun et qu'aucun champ ne correspond exactement. La version initiale de la recherche de correspondances transforme les registres correspondants identifiés au sein d'un même jeu de données. Lorsque vous ajoutez de nouvelles données au jeu de données, vous devez les fusionner avec le jeu de données propre existant et exécuter à nouveau la correspondance avec le jeu de données fusionné complet.

La fonction de correspondance progressive facilite la correspondance avec des registres progressifs en comparaison aux jeux de données appariés existants. Supposons que vous souhaitiez associer les données de prospects aux jeux de données clients existants. La fonctionnalité de correspondance progressive vous offre la flexibilité nécessaire pour associer des centaines de milliers de nouveaux

prospects à une base de données existante de prospects et de clients en fusionnant les résultats en une seule base de données ou table. En faisant correspondre uniquement les jeux de données nouveaux et existants, l'optimisation de recherche de correspondances progressives réduit le temps de calcul, ce qui réduit également les coûts.

L'utilisation de la correspondance progressive est similaire à celle de la Recherche de correspondances décrite dans [Didacticiel : Création d'une transformation de Machine Learning avec AWS Glue](#). Cette rubrique identifie uniquement les différences avec la correspondance progressive.

Pour en savoir plus, consultez l'article de blog sur [Correspondance progressive des données](#).

Exécution d'une tâche de correspondance progressive

Pour la procédure suivante, supposons la situation suivante :

- Vous avez exploré le jeu de données existant dans la table `first_records`. Le jeu de données `first_records` doit être un jeu de données correspondant, ou la sortie de la tâche correspondante.
 - Vous avez créé et entraîné une transformation Find matches avec AWS Glue version 2.0. Il s'agit de la seule version de AWS Glue qui prend en charge les correspondances incrémentielles.
 - Le langage ETL est Scala. Notez que Python est également pris en charge.
 - Le modèle déjà généré s'appelle `demo-xform`.
1. Analysez le jeu de données progressif vers la table `second_records`.
 2. Sur le AWS Glue console, dans le volet de navigation, choisissez Jobs.
 3. Choisissez Ajouter une tâche, et suivez les étapes de l'assistant pour créer une tâche ETL Spark avec un script généré. Choisissez les valeurs de propriété suivantes pour votre transformation :
 - a. Pour Nom, choisissez `demo-etl`.
 - b. Pour le rôle IAM, choisissez un rôle IAM autorisé à accéder aux données sources, au fichier d'étiquetage d'Amazon S3 et [AWS Glue Opérations d'API](#).
 - c. Pour Langage ETL, choisissez Scala.
 - d. Pour Nom du fichier script, choisissez `demo-etl`. Il s'agit du nom de fichier du script Scala.
 - e. Pour Source de données, choisissez `first_records`. La source de données que vous choisissez doit correspondre au schéma de source de données de la transformation Machine Learning.

- f. Pour Type de transformation, choisissez Find matching records Rechercher des enregistrements correspondants pour créer une tâche à l'aide d'une transformation Machine Learning.
 - g. Sélectionnez l'option de correspondance progressive, et pour Source de données sélectionnez la table nommée second_records.
 - h. Pour Transformation, choisissez demo-xform, la transformation de machine learning utilisée par la tâche.
 - i. Choisissez Créer des tables dans votre cible de données ou Utiliser les tables du catalogue de données et mettre à jour votre cible de données.
4. Choisissez Enregistrer la tâche et modifier le script pour afficher la page de l'éditeur de script.
 5. Choisissez Exécuter la tâche pour démarrer l'exécution de la tâche.

Utilisation FindMatches dans le cadre d'un travail visuel

Pour utiliser la FindMatches transformation dans AWS Glue Studio, vous pouvez utiliser le nœud Custom Transform qui appelle l' FindMatches API. Pour plus d'informations sur l'utilisation d'une transformation personnalisée, consultez [Creating a custom transformation](#).

Note

Actuellement, l' FindMatches API ne fonctionne qu'avec Glue 2.0. Pour exécuter une tâche avec la transformation personnalisée qui invoque l' FindMatches API, assurez-vous que AWS Glue La version se trouve Glue 2.0 dans l'onglet Détails du Job. Si la version de AWS Glue Si tel n'est pas le cas Glue 2.0, la tâche échouera lors de l'exécution avec le message d'erreur suivant : « Impossible d'importer le nom « FindMatches » depuis « awsglueml.transform » ».


Prérequis

- Pour utiliser la transformation Find Matches, ouvrez AWS Glue Studio console à <https://console.aws.amazon.com/gluestudio/>.
- Créer une transformation de machine learning. Une fois créé, un transformId est généré. Vous aurez besoin de cet identifiant pour les étapes ci-dessous. Pour plus d'informations sur la création d'une transformation de machine learning, consultez [Adding and editing machine learning transforms](#).

Ajouter une FindMatches transformation

Pour ajouter une FindMatches transformation :

1. Dans le volet AWS Glue Studio éditeur de tâches, ouvrez le panneau Ressources en cliquant sur le symbole en forme de croix dans le coin supérieur gauche du graphique visuel des tâches et choisissez une source de données en choisissant l'onglet Données. Il s'agit de la source de données pour laquelle vous souhaitez vérifier les correspondances.



2. Choisissez le nœud de source de données, puis ouvrez le panneau Ressources en cliquant sur le symbole en forme de croix dans le coin supérieur gauche du graphique visuel des tâches et recherchez « transformation personnalisée ». Choisissez le nœud Transformation personnalisée pour l'ajouter au graphique. La Transformation personnalisée est liée au nœud de source de données. Si ce n'est pas le cas, vous pouvez cliquer sur le nœud Transformation personnalisée et choisir l'onglet Propriétés du nœud, puis sous Parents du nœud, choisissez la source de données.

3. Cliquez sur le nœud de Transformation personnalisée dans le graphique visuel, puis choisissez l'onglet Propriétés du nœud et nommez la transformation personnalisée. Il est recommandé de renommer la transformation afin que son nom soit facilement identifiable dans le graphique visuel.
4. Choisissez l'onglet Transformer, dans lequel vous pouvez modifier le bloc de code. C'est ici que le code permettant d'invoquer l' FindMatches API peut être ajouté.

The screenshot shows the AWS Glue console interface. At the top, there are tabs for 'Visual', 'Script', 'Job details', 'Runs', 'Data quality New', 'Schedules', and 'Version Control'. The 'Visual' tab is selected, showing a workflow diagram. A 'Data source - S3 bucket Amazon S3' node is connected to a 'Transform - Custom code ml transform' node. The 'Transform' node has a green checkmark icon. On the right, the 'Node properties' panel is open, with the 'Transform' tab selected. It shows a 'Code block' with a pre-filled Python script:

```
1 - def MyTransform (glueContext, dfc) -> DynamicFrameCollection:
2
```

Le bloc de code contient un code prérempli pour vous aider à démarrer. Remplacez le code prérempli par le modèle ci-dessous. Le modèle comporte un espace réservé pour le transformId, que vous pouvez indiquer.

```
def MyTransform (glueContext, dfc) -> DynamicFrameCollection:
    dynf = dfc.select(list(dfc.keys())[0])
    from awsglueml.transforms import FindMatches
    findmatches = FindMatches.apply(frame = dynf, transformId = "<your id>")
```

```
return(DynamicFrameCollection({"FindMatches": findmatches}, glueContext))
```

5. Cliquez sur le nœud Transformation personnalisée dans le graphique visuel, puis ouvrez le panneau Ressources en cliquant sur le symbole en forme de croix dans le coin supérieur gauche du graphique visuel des tâches et recherchez « Collection Sélectionner depuis ». Il n'est pas nécessaire de modifier la sélection par défaut puisqu'il n'y en a qu'une seule DynamicFrame dans la collection.
6. Vous pouvez continuer à ajouter des transformations ou stocker le résultat, qui est désormais enrichi par les colonnes supplémentaires de recherche de correspondances. Si vous souhaitez référencer ces nouvelles colonnes dans les transformations en aval, vous devez les ajouter au schéma de sortie de la transformation. Le moyen le plus simple est de choisir l'onglet Aperçu des données, puis de choisir « Utiliser le schéma d'aperçu des données » dans l'onglet Schéma.
7. Pour personnaliser FindMatches, vous pouvez ajouter des paramètres supplémentaires à transmettre à la méthode « appliquer ». Voir le [FindMatches cours](#).

Ajouter une transformation FindMatches incrémentielle

Dans le cas de correspondances incrémentielles, le processus est identique à celui de l'ajout d'une FindMatches transformation, avec les différences suivantes :

- Au lieu d'un nœud parent pour la transformation personnalisée, vous avez besoin de deux nœuds parents.
- Le premier nœud parent doit être le jeu de données.
- Le deuxième nœud parent doit être le jeu de données incrémentiel.

Remplacez le transformId par votre transformId dans le bloc de code du modèle :

```
def MyTransform (glueContext, dfc) -> DynamicFrameCollection:
    dfs = list(dfc.values())
    dynf = dfs[0]
    inc_dynf = dfs[1]
    from awsglueml.transforms import FindIncrementalMatches
    findmatches = FindIncrementalMatches.apply(existingFrame = dynf, incrementalFrame
    = inc_dynf,
                                                transformId = "<your id>")
    return(DynamicFrameCollection({"FindMatches": findmatches}, glueContext))
```


- Pour les paramètres facultatifs, voir [FindIncrementalMatches class](#).

Migrer les programmes Apache Spark vers AWS Glue

Apache Spark est une plateforme open source pour les charges de travail informatiques distribuées et exécutées sur de vastes jeux de données. AWS Glue tire parti des capacités de Spark pour fournir une expérience optimisée pour l'ETL. Vous pouvez migrer des programmes Spark AWS Glue pour tirer parti de nos fonctionnalités. AWS Glue fournit les mêmes améliorations de performances que celles que vous attendez d'Apache Spark sur Amazon EMR.

Exécuter le code Spark

Le code Spark natif peut être exécuté dans un AWS Glue environnement prêt à l'emploi. Les scripts sont souvent développés en modifiant une partie de code de manière itérative, afin d'offrir un flux de travail adapté à une session interactive. Cependant, le code existant est plus adapté à une exécution dans le cadre d'une AWS Glue tâche, ce qui vous permet de planifier et d'obtenir régulièrement des journaux et des métriques pour chaque exécution de script. Vous pouvez télécharger et modifier un script existant en utilisant la console.

1. Obtenir la source de votre script. Pour besoin de cet exemple, vous utiliserez un exemple de script du référentiel Apache Spark. [Exemple de binarizer](#)
2. Dans la AWS Glue console, développez le volet de navigation de gauche et sélectionnez ETL > Jobs

Dans le panneau Créer une tâche, sélectionnez Éditeur de script Spark. Une section Options apparaîtra. Dans cette section Options, sélectionnez Chargement et modification d'un script existant.

Une section de Chargement du fichier apparaîtra. Dans cette section Chargement du fichier, cliquez sur Choisissez un fichier. Le sélecteur de fichiers de votre système s'affichera. Accédez à l'emplacement où vous avez enregistré `binarizer_example.py`, sélectionnez-le et confirmez votre choix.

Une touche Créer apparaîtra dans l'en-tête du panneau Créer une tâche. Cliquez sur cette touche.

The screenshot displays the 'Create job' page in AWS Glue Studio. At the top, there's a navigation bar with the AWS logo, 'Services' menu, a search bar, and a '[Option+S]' shortcut. Below the navigation bar, the breadcrumb 'AWS Glue Studio > Jobs' is visible. The main heading is 'Jobs Info'. The 'Create job Info' section contains five selectable options, each with a radio button and a description:

- ☐ Visual with a source and target: Start with a source, ApplyMapping transform, and target.
- ☐ Visual with a blank canvas: Author using an interactive visual interface.
- ☒ Spark script editor: Write or upload your own Spark code.
- ☐ Python Shell script editor: Write or upload your own Python shell script.
- ☐ Jupyter Notebook: Write your own code in a Jupyter Notebook for interactive development.

Below these options is the 'Options Info' section with two radio buttons:

- ☐ Create a new script with boilerplate code
- ☒ Upload and edit an existing script: Choose a local file.

The 'File upload' section includes a 'Choose file' button and a note: 'Limited to Python (*.py, *.py3) and Scala (*.scala) files only.' Below this, a file named 'binarizer_example.py' (1.45 KB) is shown with a green checkmark, indicating it has been successfully uploaded on June 21, 2022.

3. Votre navigateur accèdera à l'éditeur de script. Dans l'en-tête, cliquez sur l'onglet Détails de la tâche. Définissez le Nom et le Rôle IAM. Pour obtenir des conseils sur les rôles AWS Glue IAM, consultez [the section called “Configuration des autorisations IAM”](#).

Facultativement, définissez le Nombre de travailleurs à 2 et le Nombre de nouvelles tentatives à 1. Ces options sont utiles lors de l'exécution de tâches de production. Cependant, leur désactivation simplifiera votre expérience lors du test d'une fonctionnalité.

Dans la barre de titre, cliquez sur Enregistrer, puis sur Exécuter

The screenshot shows the AWS Glue console interface. At the top, there's a navigation bar with the AWS logo, 'Services' link, a search bar, and a '[Option+S]' shortcut. Below this, the main header shows the job name 'Binarizer Example' with a link icon, and buttons for 'Save', 'Delete', 'Actions' (with a dropdown arrow), and 'Run'. The 'Job details' tab is selected, with other tabs being 'Script', 'Runs', and 'Schedules'. The 'Basic properties' section is expanded, showing fields for 'Name' (Binarizer Example), 'Description - optional' (empty), 'IAM Role' (AWSGlueServiceRole), 'Type' (Spark), and 'Glue version' (Glue 3.0 - Supports spark 3.1, Scala 2, Python 3). A note indicates that descriptions can be up to 2048 characters long.

4. Accédez à l'onglet Exécutions. Vous verrez un panneau correspondant à l'exécution de votre tâche. Patientez quelques minutes, la page devrait s'actualiser automatiquement pour afficher Réussie comme Statut de l'exécution.

Binarizer Example Last modified on 7/13/2022, 12:24:55 PM [Save](#) [Delete](#) [Actions](#) [Run](#)

[Script](#) [Job details](#) [Runs](#) [Schedules](#)

Recent job runs (1) [Info](#)

[Refresh](#) [Previous](#) **1** [Next](#)

July 13, 2022 12:24:58 PM [Rewind job bookmark](#)

Job name	Id	Run status	Glue version
Binarizer Example	jr_EXAMPLEID	✔ Succeeded	3.0
Retry attempt number	Start time	End time	Start-up time
Initial run	July 13, 2022 12:24:58 PM	July 13, 2022 12:25:36 PM	7 seconds
Execution time	Last modified on	Trigger name	Security configuration
30 seconds	July 13, 2022 12:25:36 PM	-	-
Timeout	Max capacity	Number of workers	Worker type
2880 minutes	2 DPUs	2	G.1X
Execution class	Log group name	Cloudwatch logs	Performance and debugging recommendations
-	/aws-glue/jobs	All logs Output logs Error logs	View in CloudWatch

► **Input arguments (10)**
Arguments used when this job run was executed.

- Si vous souhaitez examiner votre sortie pour vérifier que le script Spark s'est exécuté comme prévu. Cet échantillon de script Apache Spark doit écrire une chaîne dans le flux de sortie. Vous pouvez le trouver en accédant aux Journaux sous Cloudwatch logs dans le panneau, pour l'exécution de tâche réussie. Notez l'ID d'exécution de la tâche, un identifiant généré sous le modèle Id commençant par `jr_`.

Cela ouvrira la CloudWatch console, configurée pour visualiser le contenu du groupe de AWS Glue journaux par défaut `/aws-glue/jobs/output`, filtré en fonction du contenu des flux de journaux pour l'identifiant d'exécution de la tâche. Chaque programme de travail aura généré un flux de journaux, affiché sous forme de lignes sous Flux de journaux. Un programme de travail aurait dû exécuter le code demandé. Vous devrez ouvrir tous les flux de journaux pour identifier le bon programme de travail. Une fois que vous avez trouvé le bon programme de travail, vous devriez voir la sortie du script, comme dans l'image suivante :

CloudWatch X

Search for services, features, blogs, docs, and more [Option+S]

CloudWatch > Log groups > /aws-glue/jobs/output > jr_EXAMPLEID

Log events
You can use the filter bar below to search for and match terms, phrases, or values in your log events. [Learn more about filter patterns](#)

☐ View as text

Filter events [Clear] 1m 30m 1h 12h Custom [Settings]

Timestamp	Message
2022-07-13T13:27:33.060-07:00	No older events at this moment. Retry
2022-07-13T13:27:33.062-07:00	2022-07-13 20:27:33,058 main WARN JNDI lookup class is not available because...
2022-07-13T13:27:54.066-07:00	2022-07-13 20:27:33,062 main INFO Log4j appears to be running in a Servlet e... Binarizer output with Threshold = 0.500000
2022-07-13T13:28:02.833-07:00	+---+-----+-----+-----+ id feature binarized_feature +---+-----+ +---+-----+-----+-----+ id feature binarized_feature +---+-----+ +---+-----+-----+-----+ 0 0.1 0.0 +---+-----+ +---+-----+-----+-----+ 1 0.8 1.0 +---+-----+ +---+-----+-----+-----+ 2 0.2 0.0 +---+-----+ +---+-----+-----+-----+

No newer events at this moment. Auto retry paused. [Resume](#)

Procédures communes requises pour la migration des programmes Spark

Évaluation de la prise en charge de la version de Spark

AWS Glue les versions de version définissent la version d'Apache Spark et de Python disponible pour la AWS Glue tâche. Vous pouvez trouver nos AWS Glue versions et ce qu'elles prennent en charge à l'adresse suivante [the section called “AWS Glue versions”](#). Vous devrez peut-être mettre à jour votre programme Spark pour qu'il soit compatible avec une version plus récente de Spark afin d'accéder à certaines fonctionnalités AWS Glue .

Intégration des bibliothèques tierces

De nombreux programmes Spark existants dépendront à la fois d'artefacts privés et publics. AWS Glue prend en charge les dépendances de style JAR pour les tâches Scala, ainsi que les dépendances Wheel et source Pure-Python pour les tâches Python.

Python - Pour plus d'informations sur les dépendances Python, consultez [the section called “Bibliothèques Python”](#)

Les dépendances Python courantes sont fournies dans l' AWS Glue environnement, y compris la bibliothèque [Pandas](#) couramment demandée. Les dépendances sont incluses dans la version 2.0 et

les versions ultérieures de AWS Glue . Pour plus d'informations sur les modules fournis, consultez [the section called “Modules Python déjà fournis dans AWS Glue”](#). Si vous devez fournir à une tâche une version différente d'une dépendance incluse par défaut, vous pouvez utiliser `--additional-python-modules`. Pour plus d'informations sur ces arguments, consultez [the section called “Paramètres des tâches”](#).

Vous pouvez fournir des dépendances Python supplémentaires avec l'argument de tâche `--extra-py-files`. Si vous migrez une tâche depuis un programme Spark, ce paramètre est une bonne option car il est fonctionnellement équivalent au `--py-files` flag in PySpark, et il est soumis aux mêmes limites. Pour plus d'informations sur le paramètre `--extra-py-files`, consultez [the section called “Y compris des fichiers Python dotés de fonctionnalités PySpark natives”](#)

Pour les nouvelles tâches, vous pouvez gérer les dépendances Python avec l'argument de tâche `--additional-python-modules`. L'utilisation de cet argument offre une expérience plus profonde de la gestion des dépendances. Ce paramètre prend en charge les dépendances de style Wheel, y compris celles comprenant des liaisons de codes natifs compatibles avec Amazon Linux 2.

Scala

Vous pouvez fournir des dépendances Scala supplémentaires avec l'Argument de tâche `--extra-jars`. Les dépendances doivent être hébergées dans Amazon S3, et la valeur de l'argument doit être une liste de chemins non-espacés Amazon S3 délimités par des virgules. Vous trouverez peut-être plus facile de gérer votre configuration en regroupant vos dépendances avant de les héberger et de les configurer. AWS Glue Les dépendances JAR contiennent du bytecode Java, qui peut être généré à partir de n'importe quel langage JVM. Il vous est possible d'utiliser d'autres langages JVM, tels que Java, pour écrire des dépendances personnalisées.

Gestion des informations d'identification de la source de données

Les programmes Spark existants peuvent être fournis avec une configuration complexe ou personnalisée pour l'extraction des données de leurs sources de données. Les flux d'authentification des sources de données courants sont pris en charge par AWS Glue les connexions. Pour plus d'informations sur les connexions AWS Glue , consultez [Connexion aux données](#).

AWS Glue les connexions facilitent la connexion de votre Job à divers types de magasins de données de deux manières principales : via des appels de méthode vers nos bibliothèques et en configurant la connexion réseau supplémentaire dans la AWS console. Vous pouvez également appeler le AWS SDK depuis votre tâche pour récupérer des informations à partir d'une connexion.

Appels de méthode : les AWS Glue connexions sont étroitement intégrées au catalogue de AWS Glue données, un service qui vous permet de gérer les informations relatives à vos ensembles de données, et les méthodes disponibles pour interagir avec AWS Glue les connexions en tiennent compte. Si vous avez une configuration d'authentification existante que vous souhaitez réutiliser, pour les connexions JDBC, vous pouvez accéder à votre configuration de AWS Glue connexion via la `extract_jdbc_conf` méthode indiquée sur le `GlueContext`. Pour plus d'informations, consultez [the section called “extract_jdbc_conf”](#).

Configuration de la console : les AWS Glue tâches utilisent AWS Glue les connexions associées pour configurer les connexions aux sous-réseaux Amazon VPC. Si vous gérez directement votre matériel de sécurité, vous devrez peut-être fournir un NETWORK type de connexion réseau supplémentaire dans la AWS console pour configurer le routage. Pour plus d'informations sur la connexion API AWS Glue , consultez [the section called “Connexions”](#)

Si vos programmes Spark disposent d'un flux d'authentification personnalisé ou peu commun, vous devrez peut-être gérer vos supports de sécurité manuellement. Si AWS Glue les connexions ne vous conviennent pas, vous pouvez héberger en toute sécurité les documents de sécurité dans Secrets Manager et y accéder via le boto3 ou le AWS SDK, fournis dans le cadre de la tâche.

Configuration d'Apache Spark

Les migrations complexes modifient souvent la configuration de Spark pour s'adapter à leurs charges de travail. Les versions modernes d'Apache Spark permettent de définir la configuration d'exécution à l'aide du `SparkSession`. AWS Glue Les jobs 3.0 et versions ultérieures sont fournis `SparkSession`, qui peuvent être modifiés pour définir la configuration d'exécution. [Configuration d'Apache Spark](#). Le réglage de Spark est complexe et AWS Glue ne garantit pas la prise en charge de la configuration de toutes les configurations de Spark. Si votre migration nécessite une configuration importante au niveau de Spark, contactez l'assistance.

Définition de la configuration

Les programmes Spark migrés peuvent être conçus pour adopter une configuration personnalisée. AWS Glue permet de définir la configuration au niveau de la tâche et de son exécution, via les arguments de la tâche. Pour plus d'informations sur ces arguments, consultez [the section called “Paramètres des tâches”](#). Vous pouvez accéder aux arguments de tâche dans le contexte d'une tâche par le biais de nos bibliothèques. AWS Glue fournit une fonction utilitaire fournissant une vue cohérente entre les arguments définis lors de la tâche et ceux définis lors de l'exécution de la tâche. Voir [the section called “getResolvedOptions”](#) dans Python et [the section called “GlueArgParser”](#) dans Scala.

Migration du code Java

Comme expliqué dans [the section called “Bibliothèques tierces”](#), vos dépendances peuvent contenir des classes générées par les langages JVM, tels que Java ou Scala. Vos dépendances peuvent inclure une Méthodomain. Vous pouvez utiliser une main méthode dans une dépendance comme point d'entrée pour une tâche AWS Glue Scala. Cela vous permet de rédiger votre méthode main en langage Java, ou réutilisez une méthode main empaquetée selon les normes de votre propre bibliothèque.

Pour utiliser une méthode main à partir d'une dépendance, effectuez les opérations suivantes : Effacez le contenu du volet d'édition en fournissant la valeur par défaut de l'objet GlueApp. Fournissez le nom complet d'une classe dans une dépendance en tant qu'argument de travail avec la clé `--class`. Vous devez ensuite être en mesure de déclencher une exécution de la tâche.

Vous ne pouvez pas configurer l'ordre ou la structure des AWS Glue arguments transmis à la main méthode. Si votre code existant doit lire la configuration définie AWS Glue, cela entraînera probablement une incompatibilité avec le code précédent. Si vous utilisez `getResolvedOptions`, vous ne disposerez pas d'un espace approprié pour appeler cette méthode. Envisagez d'invoquer votre dépendance directement, à partir d'une méthode principale générée par AWS Glue. Le script AWS Glue ETL suivant en montre un exemple.

```
import com.amazonaws.services.glue.util.GlueArgParser

object GlueApp {
  def main(sysArgs: Array[String]) {
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)

    // Invoke static method from JAR. Pass some sample arguments as a String[], one
    // defined inline and one taken from the job arguments, using getResolvedOptions
    com.mycompany.myproject.MyClass.myStaticPublicMethod(Array("string parameter1",
    args("JOB_NAME")))

    // Alternatively, invoke a non-static public method.
    (new com.mycompany.myproject.MyClass).someMethod()
  }
}
```


Travailler avec Ray Jobs dans AWS Glue

Cette section fournit des informations sur l'utilisation AWS Glue des tâches For Ray. Pour plus d'informations sur l'écriture de scripts AWS Glue pour Ray, consultez la [the section called “AWS Glue pour Ray”](#) section.

Rubriques

- [Commencer avec AWS Glue For Ray](#)
- [Environnements d'exécution Ray pris en charge](#)
- [Comptabilité pour les travailleurs dans les tâches Ray](#)
- [Utilisation des paramètres de tâche dans les tâches Ray](#)
- [Surveiller les tâches Ray à l'aide de métriques](#)

Commencer avec AWS Glue For Ray

Pour travailler avec AWS Glue for Ray, vous utilisez les mêmes AWS Glue tâches et sessions interactives que AWS Glue pour Spark. AWS Glue les tâches sont conçues pour exécuter le même script à une cadence récurrente, tandis que les sessions interactives sont conçues pour vous permettre d'exécuter des extraits de code de manière séquentielle sur les mêmes ressources provisionnées.


AWS Glue ETL et Ray sont différents en dessous, donc dans votre script, vous avez accès à différents outils, fonctionnalités et configurations. En tant que nouveau framework de calcul géré par AWS Glue, Ray possède une architecture différente et utilise un vocabulaire différent pour décrire ce qu'il fait. Pour plus d'informations, consultez les [livres blancs sur l'architecture](#) de la documentation Ray.

Note

AWS Glue for Ray est disponible dans l'est des États-Unis (Virginie du Nord), dans l'est des États-Unis (Ohio), dans l'ouest des États-Unis (Oregon), en Asie-Pacifique (Tokyo) et en Europe (Irlande).

Ray Jobs dans la AWS Glue Studio console

Sur la page Tâches de la AWS Glue Studio console, vous pouvez sélectionner une nouvelle option lorsque vous créez une tâche dans AWS Glue Studio l'éditeur de script Ray. Choisissez cette option pour créer une tâche Ray sur la console. Pour plus d'informations sur ces tâches et leur utilisation, consultez [Création de tâches ETL visuelles avec AWS Glue Studio](#).



AWS Glue Studio > Jobs

Jobs [Info](#)

Create job [Info](#) Create

☐ Visual with a source and target
Start with a source, ApplyMapping transform, and target.

☐ Visual with a blank canvas
Author using an interactive visual interface.

☐ Spark script editor
Write or upload your own Spark code.

☐ Python Shell script editor
Write or upload your own Python shell script.

☐ Jupyter Notebook
Write your own code in a Jupyter Notebook for interactive development.

☒ Ray script editor New
Write your own code to run on Ray.

Options [Info](#)

☒ Create a new script with boilerplate code

☐ Upload and edit an existing script
Choose a local file.

Offres d'emploi Ray dans le SDK AWS CLI et

Les tâches Ray AWS CLI utilisent les mêmes actions et paramètres du SDK que les autres tâches. AWS Glue for Ray introduit de nouvelles valeurs pour certains paramètres. Pour plus d'informations sur l'API Tâches, consultez [the section called "Tâches"](#).

Environnements d'exécution Ray pris en charge

Dans les tâches Spark, `GlueVersion` détermine les versions d'Apache Spark et de Python disponibles dans une tâche AWS Glue pour Spark. La version de Python indique la version qui est prise en charge pour les tâches de type Spark. Les environnements d'exécution Ray ne sont pas configurés de cette manière.

Pour les tâches Ray vous devez définir `GlueVersion` sur 4.0 ou supérieur. Toutefois, les versions de Ray, de Python et des bibliothèques supplémentaires disponibles dans votre tâche Ray sont déterminées par le champ `Runtime` de la définition de la tâche.

L'environnement d'exécution Ray2.4 sera disponible pendant au moins six mois après sa sortie. Au fur et à mesure de l'évolution rapide de Ray, vous pourrez intégrer les mises à jour et les améliorations de Ray dans les futures versions de l'environnement d'exécution.

Valeurs valides : Ray2.4

Valeur d'exécution	Versions Ray et Python
Ray2.4(pour AWS Glue 4,0 ou plus)	Ray 2.4.0
	Python 3.9

Informations supplémentaires

- Pour les notes de publication qui accompagnent AWS Glue les versions de Ray, voir [the section called “AWS Glue versions”](#).
- Pour les bibliothèques Python fournies dans un environnement d'exécution, consultez [the section called “Modules fournis avec les tâches Ray”](#).

Comptabilité pour les travailleurs dans les tâches Ray

AWS Glue exécute les tâches Ray sur de nouveaux types de EC2 travailleurs basés sur Graviton, qui ne sont disponibles que pour les tâches Ray. Afin de bien approvisionner ces travailleurs pour les charges de travail pour lesquelles Ray est conçu, nous fournissons un rapport différent entre les ressources de calcul et les ressources de mémoire de la plupart des travailleurs. Afin de tenir compte de ces ressources, nous utilisons l'unité de traitement des données à mémoire optimisée (M-DPU) plutôt que l'unité de traitement de données standard (DPU).

- Un M-DPU correspond à 4 V CPUs et à 32 Go de mémoire.
- Un DPU correspond à 4 V CPUs et 16 Go de mémoire. DPUs sont utilisés pour prendre en compte les ressources dans AWS Glue les tâches Spark et les travailleurs correspondants.

Les tâches Ray ont actuellement accès à un type de travailleur : Z.2X. Le Z.2X worker correspond à 2 M- DPUs (8 VCPUs, 64 Go de mémoire) et dispose de 128 Go d'espace disque. Une machine Z.2X fournit huit travailleurs Ray (un par vCPU).

Le nombre de M- DPUs que vous pouvez utiliser simultanément dans un compte est soumis à un quota de service. Pour plus d'informations sur les limites de votre AWS Glue compte, consultez la section [AWS Glue Points de terminaison et quotas](#).

Vous indiquez le nombre de composants master disponibles pour une tâche Ray avec `--number-of-workers` (`NumberOfWorkers`) dans la définition de la tâche. Pour plus d'informations sur les valeurs Ray dans l'API Tâches, consultez [the section called "Tâches"](#).

Vous pouvez également indiquer le nombre minimum de travailleurs qu'une tâche Ray doit allouer avec le paramètre de tâche `--min-workers`. Pour de plus amples informations sur la définition des paramètres de la tâche, consultez [the section called "Référence"](#).

Utilisation des paramètres de tâche dans les tâches Ray

Vous définissez les arguments pour les tâches AWS Glue Ray de la même manière que vous définissez les arguments AWS Glue pour les tâches Spark. Pour plus d'informations sur l' AWS Glue API, consultez [the section called "Tâches"](#). Vous pouvez configurer les tâches AWS Glue Ray avec différents arguments, qui sont répertoriés dans cette référence. Vous pouvez également fournir vos propres arguments.

Vous pouvez configurer une tâche via la console, dans l'onglet Job details (Détails de la tâche), sous Job Parameters (Paramètres de la tâche). Vous pouvez également configurer une tâche AWS CLI par le biais du paramètre `DefaultArguments` sur une tâche ou `Arguments` sur une exécution de tâche. Les arguments par défaut et les paramètres de la tâche restent associés à la tâche au fil des exécutions.

Par exemple, ce qui suit est la syntaxe pour exécuter une tâche en utilisant `--arguments` pour définir un paramètre spécial.

```
$ aws glue start-job-run --job-name "CSV to CSV" --arguments='--scriptLocation="s3://my_glue/libraries/test_lib.py",--test-environment="true"'
```

Après avoir défini les arguments, vous pouvez accéder aux paramètres de la tâche depuis votre tâche Ray via des variables d'environnement. Vous pouvez ainsi configurer votre tâche pour chaque exécution. Le nom de la variable d'environnement correspond au nom de l'argument de la tâche sans le préfixe `--`.

Par exemple, dans l'exemple précédent, les noms des variables sont `scriptLocation` et `test-environment`. Vous pouvez ensuite récupérer l'argument via les méthodes disponibles dans la bibliothèque standard : `test_environment = os.environ.get('test-environment')`. Pour plus d'informations sur l'accès aux variables d'environnement avec Python, consultez le [module os](#) dans la documentation Python.

Configuration de la façon dont les tâches Ray génèrent des journaux

Par défaut, les tâches Ray génèrent des journaux et des métriques qui sont envoyés à Amazon S3 CloudWatch et à Amazon S3. Vous pouvez utiliser le paramètre `--logging_configuration` pour modifier la façon dont les journaux sont générés. Vous pouvez actuellement l'utiliser pour empêcher les tâches Ray de générer différents types de journaux. Ce paramètre prend un objet JSON dont les clés correspondent aux journaux/comportements que vous souhaitez modifier. Il prend en charge les clés suivantes :

- **CLOUDWATCH_METRICS**— Configure des séries de CloudWatch métriques qui peuvent être utilisées pour visualiser l'état de santé au travail. Pour plus d'informations sur les métriques, consultez la section [the section called “Métriques des tâches Ray”](#).
- **CLOUDWATCH_LOGS**— Configure les CloudWatch journaux qui fournissent des informations détaillées au niveau de l'application Ray sur l'état d'exécution de la tâche. Pour de plus amples informations sur les journaux, veuillez consulter [the section called “Dépannage des erreurs Ray”](#).
- **S3**— Configure ce qui est AWS Glue écrit sur Amazon S3, principalement des informations similaires aux CloudWatch journaux, mais sous forme de fichiers plutôt que de flux de journaux.

Pour désactiver un comportement de journalisation de Ray, indiquez la valeur `{"IS_ENABLED": "False"}`. Par exemple, pour désactiver CloudWatch les métriques et CloudWatch les journaux, fournissez la configuration suivante :

```
"--logging_configuration": "{\n  \"CLOUDWATCH_METRICS\": {\n    \"IS_ENABLED\": \"False\"\n  },\n  \"CLOUDWATCH_LOGS\": {\n    \"IS_ENABLED\": \"False\"\n  }\n}"
```

Référence

Les tâches Ray reconnaissent les noms d'arguments suivants que vous pouvez utiliser afin de configurer l'environnement de script pour vos tâches Ray et vos exécutions de tâche :

- `--logging_configuration` : utilisé pour arrêter la génération de divers journaux créés par les tâches Ray. Ces journaux sont générés par défaut pour toutes les tâches Ray. Format : objet JSON en séquence d'échappement. Pour de plus amples informations, veuillez consulter [the section called “Configuration de la façon dont les tâches Ray génèrent des journaux”](#).
- `--min-workers` : nombre minimum de composants master alloués à une tâche Ray. Un composant master peut exécuter plusieurs réplicas, un par processeur virtuel. Format : nombre entier. Minimum : 0. Maximum : valeur spécifiée dans `--number-of-workers`

(NumberOfWorkers), dans la définition de la tâche. Pour plus d'informations sur la comptabilisation des composants master, consultez [the section called “Comptabilité pour les travailleurs dans les tâches Ray”](#).

- `--object_spilling_config`— AWS Glue for Ray prend en charge l'utilisation d'Amazon S3 pour étendre l'espace disponible dans le magasin d'objets de Ray. Pour activer ce comportement, vous pouvez fournir à Ray un objet de configuration JSON pour le déversement d'objets avec ce paramètre. Pour plus d'informations sur la configuration du déversement d'objets dans Ray, consulter [Object Spilling](#) dans la documentation Ray. Format : objet JSON.

AWS Glue for Ray ne prend en charge que le déversement sur le disque ou le déversement sur Amazon S3 en une seule fois. Vous pouvez indiquer plusieurs emplacements pour le déversement, à condition qu'ils respectent cette limite. Lors du déversement sur Amazon S3, vous devez également ajouter des autorisations IAM à votre tâche pour ce compartiment.

Lorsque vous fournissez un objet JSON en tant que configuration avec la CLI, vous devez le fournir sous forme de chaîne, avec la chaîne de l'objet JSON échappée. Par exemple, une valeur de chaîne pour le déversement vers un chemin Amazon S3 ressemblerait à ce qui suit : `"{"type": "smart_open", "params": {"uri": "s3path"}}`. Dans AWS Glue Studio, fournissez ce paramètre sous forme d'objet JSON sans mise en forme supplémentaire.

- `--object_store_memory_head` : mémoire allouée au magasin d'objets Plasma sur le nœud principal Ray. Cette instance exécute des services de gestion de clusters, ainsi que des réplicas de travail. La valeur représente un pourcentage de mémoire disponible sur l'instance après un démarrage à chaud. Vous utilisez ce paramètre pour régler les charges de travail gourmandes en mémoire. Les valeurs par défaut sont acceptables pour la plupart des cas d'utilisation. Format : entier positif. Minimum : 1. Maximum : 100.

Pour plus d'informations sur Plasma, consultez [The Plasma In-Memory Object Store](#) (Le magasin d'objets en mémoire Plasma) dans la documentation Ray.

- `--object_store_memory_worker` : mémoire allouée au magasin d'objets Plasma sur les composants master Ray. Ces instances exécutent uniquement des réplicas de travail. La valeur représente un pourcentage de mémoire disponible sur l'instance après un démarrage à chaud. Ce paramètre est utilisé pour régler les charges de travail gourmandes en mémoire. Les valeurs par défaut sont acceptables pour la plupart des cas d'utilisation. Format : entier positif. Minimum : 1. Maximum : 100.

Pour plus d'informations sur Plasma, consultez [The Plasma In-Memory Object Store](#) (Le magasin d'objets en mémoire Plasma) dans la documentation Ray.

- `--pip-install` : ensemble de packages Python à installer. Vous pouvez installer des packages depuis PyPI en utilisant cet argument. Format : liste délimitée par des virgules.

Une entrée de package PyPI est au format `package==version`, avec le nom PyPI et la version de votre package cible. Les entrées utilisent la correspondance entre versions de Python pour faire correspondre le package et la version, comme `==` et non le signe `=` seul. Il existe d'autres opérateurs de mise en correspondance des versions. Pour plus d'informations, consultez [PEP 440](#) sur le site Internet de Python. Vous pouvez également fournir des modules personnalisés avec `--s3-py-modules`.

- `--s3-py-modules` : un ensemble de chemins Amazon S3 qui hébergent des distributions de modules Python. Format : liste délimitée par des virgules.

Vous pouvez l'utiliser pour distribuer vos propres modules à votre tâche Ray. Vous pouvez également fournir des modules à partir de PyPI avec `--pip-install`. Contrairement à l'AWS Glue ETL, les modules personnalisés ne sont pas configurés via pip, mais sont transmis à Ray pour distribution. Pour de plus amples informations, veuillez consulter [the section called “Modules Python supplémentaires pour les tâches Ray”](#).

- `--working-dir` : un chemin d'accès à un fichier .zip hébergé sur Amazon S3 contenant les fichiers à distribuer à tous les nœuds exécutant votre tâche Ray. Format : chaîne. Pour de plus amples informations, veuillez consulter [the section called “Fournir des fichiers à votre tâche Ray”](#).

Surveiller les tâches Ray à l'aide de métriques

Vous pouvez suivre les jobs de Ray à l'aide AWS Glue Studio d'Amazon CloudWatch. CloudWatch collecte et traite les métriques brutes issues AWS Glue de Ray, ce qui les rend disponibles pour analyse. Ces mesures sont visualisées dans la AWS Glue Studio console, afin que vous puissiez surveiller votre tâche pendant son exécution.

Pour une présentation générale du mode de surveillance AWS Glue, voir [the section called “Utilisation de CloudWatch métriques”](#). Pour un aperçu général de l'utilisation CloudWatch des métriques publiées par AWS Glue, voir [the section called “Surveillance avec CloudWatch”](#).

Surveillance des tâches de Ray dans la AWS Glue console

Sur la page de détails d'une exécution de tâche, sous la section Détails de l'exécution, vous pouvez consulter des graphiques agrégés prédéfinis qui visualisent les indicateurs de vos tâches disponibles. AWS Glue Studio envoie des métriques de tâche CloudWatch pour chaque exécution de tâche. Vous

pouvez ainsi créer un profil de votre cluster et de vos tâches, ainsi qu'accéder à des informations détaillées sur chaque nœud.

Pour plus d'informations sur les graphiques de métriques disponibles, consultez [the section called “Afficher Amazon CloudWatch les statistiques relatives à l'exécution d'une tâche Ray”](#).

Vue d'ensemble des indicateurs de Ray Jobs dans CloudWatch

Nous publions les métriques Ray lorsque la surveillance détaillée est activée dans CloudWatch. Les métriques sont publiées dans l'espace de Glue/Ray CloudWatch noms.

- Métriques des instances

Nous publions des métriques sur l'utilisation du processeur, de la mémoire et du disque des instances affectées à une tâche. Ces métriques sont identifiées par des fonctionnalités telles que `ExecutorId`, `ExecutorType` et `host`. Ces métriques constituent un sous-ensemble des métriques standard des CloudWatch agents Linux. Vous trouverez des informations sur les noms et les fonctionnalités des métriques dans la CloudWatch documentation. Pour plus d'informations, consultez la section [Mesures collectées par l' CloudWatch agent](#).

- Métriques du cluster Ray

Nous transmettons les métriques des processus Ray qui exécutent votre script à cet espace de noms, puis nous vous fournissons celles qui sont les plus essentielles pour vous. Les mesures disponibles peuvent varier selon la version de Ray. Pour plus d'informations sur la version de Ray exécutée par votre tâche, consultez [the section called “AWS Glue versions”](#).

Ray collecte des métriques au niveau de l'instance. Il fournit également des métriques pour les tâches et le cluster. Pour plus d'informations sur la stratégie métrique sous-jacente de Ray, consultez [Metrics](#) dans la documentation Ray.

Note

Nous ne publions pas les métriques Ray dans l'espace de noms Glue/Job Metrics/, qui n'est utilisé que pour les tâches AWS Glue ETL.

Configuration des propriétés des tâches pour les tâches du shell Python dans AWS Glue

Vous pouvez utiliser une tâche shell Python pour exécuter des scripts Python en tant que shell dans AWS Glue. Avec une tâche shell Python, vous pouvez exécuter des scripts compatibles avec Python 3.6 ou Python 3.9.

Note

Support pour Pyshell v3.6 prendra fin le 1er mars 2026. Pour migrer vos charges de travail, voir [Migrer depuis des tâches shell AWS Glue Python](#). Si vous souhaitez continuer avec Python shell v3.9, voir [Migration du shell Python 3.6 vers le shell Python 3.9](#).

Rubriques

- [Limites](#)
- [Définition des propriétés pour les tâches shell Python](#)
- [Bibliothèques prises en charge pour les tâches shell Python](#)
- [Ajout de votre propre bibliothèque Python](#)
- [À utiliser AWS CloudFormation avec les jobs shell Python dans AWS Glue](#)
- [Migration du shell Python 3.6 vers le shell Python 3.9](#)
- [Migrer depuis les jobs shell AWS Glue Python](#)

Limites

Notez les limitations suivantes des tâches shell Python :

- Vous ne pouvez pas utiliser les signets de tâche avec les tâches shell Python.
- Vous ne pouvez pas emballer des bibliothèques Python sous forme de `.egg` fichiers dans Python 3.9+. Utilisez à la place `.whl`.
- L'option `--extra-files` ne peut pas être utilisée en raison de la limitation des copies temporaires des données S3.

Définition des propriétés pour les tâches shell Python

Ces sections décrivent la définition des propriétés des tâches dans AWS Glue Studio, ou en utilisant la AWS CLI.

AWS Glue Studio

Lorsque vous définissez votre tâche shell Python dans AWS Glue Studio, vous fournissez certaines des propriétés suivantes :

Rôle IAM

Spécifiez le rôle AWS Identity and Access Management (IAM) utilisé pour autoriser les ressources utilisées pour exécuter le travail et accéder aux magasins de données. Pour plus d'informations sur les autorisations relatives à l'exécution de tâches dans AWS Glue, voir [Gestion des identités et des accès pour AWS Glue](#).

Type

Choisissez Python shell (shell Python) pour exécuter un script Python avec la commande de tâche nommée `pythonshell`.

Version Python

Choisissez la version Python. La valeur par défaut est Python 3.9. Les versions valides sont Python 3.6 et Python 3.9.

Charger des bibliothèques d'analyse courantes (recommandé)

Choisissez cette option pour inclure les bibliothèques courantes pour Python 3.9 dans le Python shell.

Si vos bibliothèques sont personnalisées ou si elles sont en conflit avec les bibliothèques préinstallées, vous pouvez choisir de ne pas installer de bibliothèques courantes. Cependant, vous pouvez installer des bibliothèques supplémentaires en plus des bibliothèques courantes.

Lorsque vous sélectionnez cette option, l'option `library-set` est définie sur `analytics`. Lorsque vous désélectionnez cette option, l'option `library-set` est définie sur `none`.

Nom du fichier de script et chemin du script

Le code inclus dans le script permet de définir la logique procédurale de votre tâche. Vous fournissez le nom et l'emplacement du script dans Amazon Simple Storage Service (Amazon

S3). Vérifiez qu'il n'existe pas de fichier portant le même nom que le répertoire de script dans le chemin d'accès. Pour en savoir plus sur les scripts, consultez [AWS Glue guide de programmation](#).

Script

Le code inclus dans le script permet de définir la logique procédurale de votre tâche. Vous pouvez coder ce script dans Python 3.6 ou Python 3.9. Vous pouvez modifier un script dans AWS Glue Studio.

Unités de traitement de données

Le nombre maximum de AWS Glue unités de traitement de données (DPUs) qui peuvent être allouées lors de l'exécution de cette tâche. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour de plus amples informations, consultez [AWS Glue tarification](#).

Vous pouvez affecter la valeur 0.0625 ou 1. La valeur par défaut est 0.0625. Dans les deux cas, le disque local de l'instance sera de 20 Go.

INTERFACE DE LIGNE DE COMMANDE (CLI)

Vous pouvez également créer une tâche shell Python à l'aide de AWS CLI, comme dans l'exemple suivant.

```
aws glue create-job --name python-job-cli --role Glue_DefaultRole
  --command '{"Name" : "pythonshell", "PythonVersion": "3.9", "ScriptLocation" :
"s3://amzn-s3-demo-bucket/scriptname.py"}'
  --max-capacity 0.0625
```

Note

Il n'est pas nécessaire de spécifier la version de AWS Glue puisque le paramètre `--glue-version` ne s'applique pas à AWS Glue emplois fictifs. Toute version spécifiée sera ignorée.

Tâches que vous créez avec Python 3 AWS CLI par défaut. Les versions valides de Python sont 3 (correspondant à 3.6), et 3.9. Pour spécifier Python 3.6, ajoutez ce tuple au paramètre `--command` : `"PythonVersion": "3"`

Pour spécifier Python 3.9, ajoutez ce tuple au paramètre `--command` : `"PythonVersion": "3.9"`

Pour définir la capacité maximale utilisée par une tâche shell Python, définissez le paramètre `--max-capacity`. Pour les tâches shell Python, le paramètre `--allocated-capacity` ne peut pas être utilisé.

Bibliothèques prises en charge pour les tâches shell Python

Dans le Python shell utilisant Python 3.9, vous pouvez choisir l'ensemble de bibliothèques qui utilisera les ensembles de bibliothèques préemballés selon vos besoins. Vous pouvez utiliser l'option `library-set` pour choisir l'ensemble de bibliothèques. Les valeurs valides sont `analytics`, et `none`.

L'environnement pour exécuter une tâche shell Python prend en charge les bibliothèques suivantes :

Version Python	Python 3.6	Python 3.9	
Ensemble de bibliothèques	S/O	analytique	Aucun(e)
avro		1.11.0	
awscli	116,242	1,23,5	1,23,5
awswrangler		2.15.1	
botocore	1,12,232	1,24,21	1,23,5
boto3	1,9,203	1,21,21	
elasticsearch		8.2.0	
numpy	1.16,2	1.22.3	
pandas	0,24,2	1.4.2	
psycopg2		2.9.3	
pyathena		2.5.3	
PyGreSQL	5.0.6		
PyMySQL		1.0.2	

Version Python	Python 3.6	Python 3.9	
pyodbc		4,0,32	
pyorc		0.6.0	
redshift-connector		2,0.907	
demandes	2.22.0	2.27.1	
scikit-learn	0,20,3	1.0.2	
scipy	1.2.1	1.8.0	
SQLAlchemy		1,4,36	
s3fs		2022.3.0	

Vous pouvez utiliser la bibliothèque NumPy dans une tâche shell Python à des fins de calcul scientifique. Pour de plus amples informations, veuillez consulter [NumPy](#). L'exemple suivant montre un NumPy script qui peut être utilisé dans une tâche shell Python. Le script inscrit « Hello world » et les résultats de plusieurs calculs mathématiques.

```
import numpy as np
print("Hello world")

a = np.array([20,30,40,50])
print(a)

b = np.arange( 4 )

print(b)

c = a-b

print(c)

d = b**2

print(d)
```

Ajout de votre propre bibliothèque Python

Utilisation de PIP

Le Python shell utilisant Python 3.9 vous permet de fournir des modules Python supplémentaires ou des versions différentes au niveau de la tâche. Vous pouvez utiliser l'option `--additional-python-modules` avec une liste de modules Python séparés par des virgules pour ajouter un nouveau module ou modifier la version d'un module existant. Vous ne pouvez pas fournir de modules Python personnalisés hébergés sur Amazon S3 avec ce paramètre lorsque vous utilisez des tâches shell Python.

Par exemple, pour mettre à jour ou ajouter un nouveau module `scikit-learn`, utilisez la clé et la valeur suivantes : `--additional-python-modules`, `"scikit-learn==0.21.3"`.

AWS Glue utilise le Python Package Installer (pip3) pour installer les modules supplémentaires. Vous pouvez transmettre des options pip3 supplémentaires à l'intérieur de la valeur `--additional-python-modules`. Par exemple, `"scikit-learn==0.21.3 -i https://pypi.python.org/simple/"`. Toutes les incompatibilités ou limitations de pip3 s'appliquent.

Note

Pour éviter les incompatibilités à l'avenir, nous vous recommandons d'utiliser des bibliothèques créées pour Python 3.9.

Utilisation d'un fichier Egg ou Whl

Vous avez peut-être déjà une ou plusieurs bibliothèques Python empaquetées sous la forme d'un fichier `.egg` ou `.whl`. Le cas échéant, vous pouvez les spécifier pour votre tâche à l'aide du AWS Command Line Interface (AWS CLI) sous l'indicateur « `--extra-py-files` », comme dans l'exemple suivant.

```
aws glue create-job --name python-redshift-test-cli --role role --command '{"Name" :  
  "pythonshell", "ScriptLocation" : "s3://MyBucket/python/library/redshift_test.py"}'  
  --connections Connections=connection-name --default-arguments '{"--extra-py-  
files" : ["s3://amzn-s3-demo-bucket/EGG-FILE", "s3://amzn-s3-demo-bucket/WHEEL-FILE"]}'
```

Si vous n'êtes pas sûr de la façon de créer un fichier `.egg` ou `.whl` à partir d'une bibliothèque Python, procédez comme suit. Cet exemple est applicable sur macOS, Linux et WSL (sous-système Windows pour Linux).

Pour créer un fichier Python `.egg` ou `.whl`

1. Créez un cluster Amazon Redshift dans un Virtual Private Cloud (VPC) et ajoutez des données dans une table.
2. Créez un AWS Glue connexion pour la VPC-SecurityGroup-Subnet combinaison que vous avez utilisée pour créer le cluster. Testez le bon fonctionnement de cette connexion.
3. Créez un répertoire nommé `redshift_example` et un fichier nommé `setup.py`. Collez le code suivant dans `.`

```
from setuptools import setup

setup(
    name="redshift_module",
    version="0.1",
    packages=['redshift_module']
)
```

4. Dans le répertoire `redshift_example`, créez un répertoire `redshift_module`. Dans le répertoire `redshift_module`, créez les fichiers `__init__.py` et `pygresql_redshift_common.py`.
5. Laissez le fichier `__init__.py` vide. Collez le code suivant dans `pygresql_redshift_common.py`. Remplacez `portdb_name`, `user`, et par `password_for_user` des informations spécifiques à votre cluster Amazon Redshift. Remplacez `table_name` par le nom de la table dans Amazon Redshift.

```
import pg

def get_connection(host):
    rs_conn_string = "host=%s port=%s dbname=%s user=%s password=%s" % (
        host, port, db_name, user, password_for_user)

    rs_conn = pg.connect(dbname=rs_conn_string)
    rs_conn.query("set statement_timeout = 1200000")
    return rs_conn
```

```
def query(con):  
    statement = "Select * from table_name;"  
    res = con.query(statement)  
    return res
```

6. Si vous n'êtes pas déjà dans le répertoire `redshift_example`, accédez-y.
7. Effectuez l'une des actions suivantes :

- Pour créer un fichier `.egg`, exécutez la commande suivante :

```
python setup.py bdist_egg
```

- Pour créer un fichier `.whl`, exécutez la commande suivante.

```
python setup.py bdist_wheel
```

8. Installez les dépendances qui sont nécessaires à la commande précédente.
9. La commande crée un fichier dans le répertoire `dist` :
 - Si vous avez créé un fichier `egg`, il est nommé `redshift_module-0.1-py2.7.egg`.
 - Si vous avez créé un fichier `Wheel`, il est nommé `redshift_module-0.1-py2.7-none-any.whl`.

Téléchargez vos fichiers sur Amazon S3.

Dans cet exemple, le chemin du fichier chargé est `s3://amzn-s3-demo-bucket/EGG-FILE` ou `s3://amzn-s3-demo-bucket/WHEEL-FILE`.

10. Créez un fichier Python à utiliser comme script pour le AWS Glue job, et ajoutez le code suivant au fichier.

```
from redshift_module import pygresql_redshift_common as rs_common  
  
con1 = rs_common.get_connection(redshift_endpoint)  
res = rs_common.query(con1)  
  
print "Rows in the table cities are: "  
  
print res
```


11. Téléchargez le fichier précédent sur Amazon S3. Dans cet exemple, le chemin du fichier chargé est `s3://amzn-s3-demo-bucket/scriptname.py`.
12. Créez une tâche shell Python à l'aide de ce script. Sur le AWS Glue console, sur la page des propriétés du Job, spécifiez le chemin du `.egg/.whl` fichier dans le champ Chemin de la bibliothèque Python. Si vous avez plusieurs fichiers `.egg/.whl` et fichiers Python, indiquez-les dans cette zone sous forme de liste de valeurs séparées par des virgules.

Lors de la modification ou du changement de nom de fichiers `.egg`, les noms de ces derniers doivent utiliser les noms par défaut générés par la commande « `python setup.py bdist_egg` » ou doivent respecter les conventions de dénomination du module Python. Pour plus d'informations, consultez [Style Guide for Python Code](#) (Guide de style pour le code Python).

À l'aide de AWS CLI, créez une tâche avec une commande, comme dans l'exemple suivant.

```
aws glue create-job --name python-redshift-test-cli --role Role --command
'{"Name" : "pythonshell", "ScriptLocation" : "s3://amzn-s3-demo-bucket/
scriptname.py"}'
    --connections Connections="connection-name" --default-arguments '{"--extra-
py-files" : ["s3://amzn-s3-demo-bucket/EGG-FILE", "s3://amzn-s3-demo-bucket/WHEEL-
FILE"]}'
```

Lorsque le job s'exécute, le script imprime les lignes créées dans la `table_name` table du cluster Amazon Redshift.

À utiliser AWS CloudFormation avec les jobs shell Python dans AWS Glue

Vous pouvez utiliser AWS CloudFormation avec Python des jobs shell dans AWS Glue. Voici un exemple :

```
AWSTemplateFormatVersion: 2010-09-09
Resources:
  Python39Job:
    Type: 'AWS::Glue::Job'
    Properties:
      Command:
        Name: pythonshell
        PythonVersion: '3.9'
        ScriptLocation: 's3://bucket/location'
```

```
MaxRetries: 0
Name: python-39-job
Role: RoleName
```

Le groupe Amazon CloudWatch Logs pour les résultats des tâches shell Python est `/aws-glue/python-jobs/output`. Pour les erreurs, consultez le groupe de journaux `/aws-glue/python-jobs/error`.

Migration du shell Python 3.6 vers le shell Python 3.9

Pour migrer vos jobs shell Python vers la dernière AWS Glue version :

1. Dans la AWS Glue console (<https://console.aws.amazon.com/glue/>), choisissez votre job shell Python existant.
2. Dans l'onglet Détails du Job, définissez la version de Python sur Python 3.9 et choisissez Enregistrer.
3. Assurez-vous que votre script de tâche est compatible avec Python 3.9 et qu'il s'exécute correctement.

Migrer depuis les jobs shell AWS Glue Python

AWS a lancé les jobs shell AWS Glue Python en 2018 afin de permettre aux clients d'exécuter facilement des scripts Python pour des tâches ETL de small-to-medium grande taille et de déclencher des requêtes SQL. Cependant, il existe désormais des options plus modernes et plus flexibles pour faire face aux charges de travail actuelles. PythonShell Cette rubrique explique comment migrer vos charges de travail depuis les jobs shell AWS Glue Python vers l'une de ces options alternatives afin de tirer parti des nouvelles fonctionnalités disponibles.

Cette rubrique explique comment migrer des jobs shell AWS Glue Python vers des options alternatives.

Migration de la charge de travail vers les tâches AWS Glue Spark

[AWS Glue Spark et les PySpark jobs](#) vous permettent d'exécuter vos charges de travail de manière distribuée. Comme les jobs AWS Glue Python Shell et les jobs AWS Glue Spark s'exécutent sur la même plateforme, la migration est facile et vous pouvez continuer à utiliser les fonctionnalités AWS

Glue existantes que vous utilisez avec les tâches Python Shell, telles que AWS Glue Workflows, AWS Glue Triggers, Amazon EventBridge l'intégration de AWS Glue, l'installation de packages basée sur \ Pip, etc.

Cependant, les tâches AWS Glue Spark sont conçues pour exécuter des charges de travail Spark, et le nombre minimum de travailleurs est de 2. Si vous migrez à partir de tâches Python Shell sans modifier vos scripts, un seul programme de travail sera réellement utilisé et les autres resteront inactifs. Cela augmentera vos coûts.

Pour le rendre efficace, réécrivez votre script de travail Python afin d'utiliser les fonctionnalités de Spark et de répartir la charge de travail entre plusieurs travailleurs. Si votre script Python est basé sur Pandas, il est facile de le migrer à l'aide de l'API New Pandas sur Spark. Pour en savoir plus, consultez [le blog AWS Big Data : Dive deep into AWS Glue 4.0 pour Apache Spark](#).

Migration de la charge de travail vers AWS Lambda

AWS Lambda est un service informatique sans serveur qui vous permet d'exécuter du code sans provisionner ni gérer de serveurs. Grâce AWS Lambda à des temps de démarrage plus courts et à des options de capacité de calcul plus flexibles, vous pouvez bénéficier de ces avantages. Pour gérer des bibliothèques Python supplémentaires, les jobs AWS Glue Python Shell utilisent une installation basée sur PIP. Cependant, pour AWS Lambda, vous devez choisir l'une des options suivantes : une archive zip, une image de conteneur ou des couches Lambda.

En revanche, le délai maximum AWS Lambda est de 900 secondes (15 minutes). Si la durée de travail de votre charge de travail AWS Glue Python Shell existante est supérieure à ce montant, ou si votre charge de travail présente un schéma épineux susceptible de prolonger la durée des tâches, nous vous recommandons d'explorer d'autres options au lieu de. AWS Lambda

Migration de la charge de travail vers Amazon ECS/Fargate

Amazon Elastic Container Service (Amazon ECS) est un service entièrement géré qui simplifie le déploiement, la gestion et le dimensionnement des applications conteneurisées. AWS Fargate est un moteur de calcul sans serveur pour les charges de travail conteneurisées exécutées sur Amazon ECS et (Amazon Elastic Kubernetes Service Amazon EKS). Il n'y a pas de délai d'expiration maximal sur Amazon ECS et Fargate, c'est donc une bonne option pour les tâches de longue durée. Comme vous avez le contrôle total de l'image de votre conteneur, vous pouvez importer votre script Python et des bibliothèques Python supplémentaires dans le conteneur et les utiliser. Cependant, vous devez conteneuriser votre script Python pour utiliser cette approche.

Migration de la charge de travail vers Amazon Managed Workflows pour Apache Airflow Python Operator

Amazon Managed Workflows for Apache Airflow (Managed Workflows for Apache Airflow) est un service d'orchestration géré pour Apache Airflow qui facilite la configuration et l'exploitation de pipelines de end-to-end données dans le cloud à grande échelle. Si vous avez déjà un environnement MWAA, il sera facile d'utiliser l'opérateur Python au lieu des jobs AWS Glue Python Shell. L'opérateur Python est un opérateur qui exécute du code Python dans un flux de travail Airflow. Toutefois, si vous ne disposez pas d'un environnement MWAA existant, nous vous recommandons d'explorer d'autres options.

Migration de la charge de travail vers des postes de formation en Amazon SageMaker AI IA

Amazon SageMaker AI La formation est un service d'apprentissage automatique (ML) entièrement géré Amazon SageMaker AI qui vous aide à entraîner efficacement un large éventail de modèles de machine learning à grande échelle. La conteneurisation des charges de travail de machine learning et la capacité de gérer AWS les ressources informatiques sont au cœur des métiers de l'Amazon SageMaker AI IA. Si vous préférez un environnement sans serveur où il n'y a pas de délai d'attente maximal, les emplois de formation en Amazon SageMaker AI IA pourraient vous convenir. Cependant, la latence de démarrage a tendance à être plus longue que celle des jobs AWS Glue Python Shell. Pour les tâches sensibles à la latence, nous vous recommandons d'explorer d'autres options.

Surveillance AWS Glue

La surveillance joue un rôle important dans le maintien de la fiabilité, de la disponibilité AWS Glue et des performances de vos autres AWS solutions. AWS fournit des outils de surveillance que vous pouvez utiliser pour surveiller AWS Glue, signaler un problème et prendre des mesures automatiquement le cas échéant :

Vous pouvez utiliser les outils de surveillance automatique pour surveiller AWS Glue et signaler en cas de problème :

- Amazon CloudWatch Events fournit un flux en temps quasi réel d'événements système décrivant les modifications apportées aux AWS ressources. CloudWatch Les événements permettent une informatique automatisée axée sur les événements. Vous pouvez rédiger des règles qui surveillent certains événements et déclenchent des actions automatisées dans d'autres AWS services

lorsque ces événements se produisent. Pour plus d'informations, consultez le [guide de l'utilisateur d'Amazon CloudWatch Events](#).

- Amazon CloudWatch Logs vous permet de surveiller, de stocker et d'accéder à vos fichiers journaux à partir d' EC2 instances Amazon et d'autres sources. AWS CloudTrail CloudWatch Les journaux peuvent surveiller les informations contenues dans les fichiers journaux et vous avertir lorsque certains seuils sont atteints. Vous pouvez également archiver vos données de journaux dans une solution de stockage hautement durable. Pour plus d'informations, consultez le [guide de l'utilisateur d'Amazon CloudWatch Logs](#).
- AWS CloudTrail capture les appels d'API et les événements associés effectués par ou pour le compte de votre AWS compte et envoie les fichiers journaux dans un compartiment Amazon S3 que vous spécifiez. Vous pouvez identifier les utilisateurs et les comptes qui appellent AWS, l'adresse IP source à partir de laquelle les appels sont effectués et le moment où les appels ont lieu. Pour plus d'informations, consultez le [AWS CloudTrail Guide de l'utilisateur](#).

En outre, vous avez accès aux informations suivantes dans la AWS Glue console pour vous aider à déboguer et à profiler les tâches :

- Jobs Spark : vous pouvez voir une visualisation des séries de CloudWatch métriques sélectionnées, et les nouveaux jobs ont accès à l'interface utilisateur de Spark. Pour de plus amples informations, veuillez consulter [the section called “Surveillance des tâches Spark”](#).
- Ray Jobs : vous pouvez voir une visualisation des séries de CloudWatch mesures sélectionnées. Pour de plus amples informations, veuillez consulter [the section called “Métriques des tâches Ray”](#).

Rubriques

- [AWS tags dans AWS Glue](#)
- [Automatiser AWS Glue avec EventBridge](#)
- [AWS Glue Ressources de surveillance](#)
- [Journalisation AWS Glue Appels d'API avec AWS CloudTrail](#)

AWS tags dans AWS Glue

Pour vous aider à gérer votre AWS Glue ressources, vous pouvez éventuellement attribuer vos propres balises à certaines AWS Glue types de ressources. Une étiquette est une étiquette que vous attribuez à une AWS ressource. Chaque balise est constituée d'une clé et d'une valeur facultative

que vous définissez. Vous pouvez utiliser des balises dans AWS Glue pour organiser et identifier vos ressources. Des balises peuvent être utilisées pour créer des rapports de comptabilisation des coûts et limiter l'accès aux ressources. Si vous en utilisez AWS Identity and Access Management, vous pouvez contrôler quels utilisateurs de votre AWS compte sont autorisés à créer, modifier ou supprimer des tags. Outre les autorisations d'appel liées à l'étiquette APIs, vous devez également être `glue:GetConnection` autorisée à étiqueter les appels APIs sur les connexions et à étiqueter les `glue:GetDatabase` appels sur les bases de données APIs . Pour de plus amples informations, veuillez consulter [ABAC avec Glue AWS](#).

Entrée AWS Glue, vous pouvez baliser les ressources suivantes :

- Connexion
- Base de données
- crawler
- Séance interactive
- Point de terminaison de développement
- Tâche
- Déclencheur
- Flux de travail
- Plan
- Transformation de machine learning
- Ensemble de règles de qualité des données
- Schémas de flux
- Registres de schémas de flux

 Note

À titre de bonne pratique, pour autoriser le balisage de ces AWS Glue ressources, incluez toujours `glue:TagResource` dans vos politiques.

Tenez compte des points suivants lorsque vous utilisez des balises avec AWS Glue.

- Un maximum de 50 balises sont prises en charge par entité.

- Entrée AWS Glue, vous spécifiez les balises sous forme de liste de paires clé-valeur au format `{"string": "string" ...}`
- Lorsque vous créez une balise sur un objet, la clé de balise est obligatoire et la valeur de balise est facultative.
- La clé de balise et la valeur de balise sont sensibles à la casse.
- La clé de balise et la valeur de balise ne doivent pas contenir le préfixe `aws`. Aucune opération n'est autorisée sur ces balises.
- La longueur maximale des clés de balise est de 128 caractères Unicode en UTF-8. La clé de balise ne doit pas être vide ni null.
- La longueur maximale des valeurs de balise est de 256 caractères Unicode en UTF-8. La valeur de balise peut être vide ou null.

Support de balisage pour les connexions AWS Glue

Vous pouvez restreindre l'autorisation d'actions `CreateConnection`, `UpdateConnection`, `GetConnection` et `DeleteConnection` en fonction d'identification de ressources. Cela vous permet de mettre en œuvre le contrôle d'accès avec le moindre privilège sur les AWS Glue tâches comportant des sources de données JDBC qui doivent extraire les informations de connexion JDBC depuis le catalogue de données.

Exemple d'utilisation

Créez une AWS Glue connexion avec le tag `["connection-category » , « dev-test"]`.

Spécifiez la condition de l'identification pour l'action `GetConnection` dans la politique IAM.

```
{
  "Effect": "Allow",
  "Action": [
    "glue:GetConnection"
  ],
  "Resource": "*",
  "Condition": {
    "ForAnyValue:StringEquals": {
      "aws:ResourceTag/tagKey": "dev-test"
    }
  }
}
```

Exemples

Les exemples suivants créent une tâche avec des balises attribuées.

AWS CLI

```
aws glue create-job --name job-test-tags --role MyJobRole --command  
Name=glueetl,ScriptLocation=S3://aws-glue-scripts//prod-job1  
--tags key1=value1,key2=value2
```

AWS CloudFormation JSON

```
{  
  "Description": "AWS Glue Job Test Tags",  
  "Resources": {  
    "MyJobRole": {  
      "Type": "AWS::IAM::Role",  
      "Properties": {  
        "AssumeRolePolicyDocument": {  
          "Version": "2012-10-17",  
          "Statement": [  
            {  
              "Effect": "Allow",  
              "Principal": {  
                "Service": [  
                  "glue.amazonaws.com"  
                ]  
            },  
              "Action": [  
                "sts:AssumeRole"  
              ]  
            }  
          ]  
        },  
        "Path": "/",  
        "Policies": [  
          {  
            "PolicyName": "root",  
            "PolicyDocument": {  
              "Version": "2012-10-17",  
              "Statement": [  
                {  
                  "Effect": "Allow",
```



```

        "Action": "*",
        "Resource": "*"
      }
    ]
  }
}
],
"Jobs": [
  {
    "Name": "cf-job1",
    "Type": "AWS::Glue::Job",
    "Properties": {
      "Command": {
        "Name": "glueetl",
        "ScriptLocation": "s3://aws-glue-scripts//prod-job1"
      },
      "DefaultArguments": {
        "--job-bookmark-option": "job-bookmark-enable"
      },
      "ExecutionProperty": {
        "MaxConcurrentRuns": 2
      },
      "MaxRetries": 0,
      "Role": {
        "Ref": "MyJobRole",
        "Tags": {
          "key1": "value1",
          "key2": "value2"
        }
      }
    }
  }
]
}
}
}

```

AWS CloudFormation YAML

```

Description: AWS Glue Job Test Tags
Resources:
  MyJobRole:
    Type: AWS::IAM::Role
    Properties:

```

```
AssumeRolePolicyDocument:
  Version: '2012-10-17'
  Statement:
    - Effect: Allow
      Principal:
        Service:
          - glue.amazonaws.com
      Action:
        - sts:AssumeRole
  Path: "/"
  Policies:
    - PolicyName: root
      PolicyDocument:
        Version: '2012-10-17'
        Statement:
          - Effect: Allow
            Action: "*"
            Resource: "*"
MyJob:
```

```
  Type: AWS::Glue::Job
```

```
  Properties:
```

```
    Command:
```

```
      Name: glueetl
```

```
      ScriptLocation: s3://aws-glue-scripts//prod-job1
```

```
    DefaultArguments:
```

```
      "--job-bookmark-option": job-bookmark-enable
```

```
    ExecutionProperty:
```

```
      MaxConcurrentRuns: 2
```

```
    MaxRetries: 0
```

```
    Name: cf-job1
```

```
    Role:
```

```
      Ref: MyJobRole
```

```
    Tags:
```

```
      key1: value1
```

```
      key2: value2
```

Pour de plus amples informations, veuillez consulter [Politiques de balisage AWS](#).

Pour obtenir des informations sur la façon de contrôler l'accès à l'aide de balises, consultez [ABAC avec Glue AWS](#).

Automatiser AWS Glue avec EventBridge

Vous pouvez utiliser Amazon EventBridge pour automatiser vos AWS services et répondre automatiquement aux événements du système tels que les problèmes de disponibilité des applications ou les modifications des ressources. Les événements AWS liés aux services sont diffusés EventBridge en temps quasi réel. Vous pouvez écrire des règles simples pour indiquer quels événements vous intéressent et les actions automatisées à effectuer quand un événement correspond à une règle. Les actions pouvant être déclenchées automatiquement sont les suivantes :

- Invoquer une fonction AWS Lambda
- Invocation de la commande Amazon EC2 Run
- Relais de l'événement à Amazon Kinesis Data Streams
- Activation d'une machine à AWS Step Functions états
- Notification d'une rubrique Amazon SNS ou d'une file d'attente Amazon SQS

Quelques exemples d'utilisation EventBridge avec AWS Glue comprennent notamment :

- Activation d'une fonction Lambda lorsqu'une tâche ETL réussit
- Notification d'une rubrique Amazon SNS lorsqu'une tâche ETL échoue

Les éléments suivants EventBridge sont générés par AWS Glue.

- Les événements pour "detail-type":"Glue Job State Change" sont générés pour SUCCEEDED, FAILED, TIMEOUT et STOPPED.
- Les événements pour "detail-type":"Glue Job Run Status" sont générés pour les exécutions de tâche RUNNING, STARTING et STOPPING lorsqu'ils dépassent le seuil de notification de dépassement de délai de tâche. Vous devez définir la propriété du seuil de notification des retards de tâche pour recevoir ces événements.

Un seul événement est généré par statut d'exécution de tâche lorsque le seuil de notification de retard de tâche est dépassé.

- Les événements pour "detail-type":"Glue Crawler State Change" sont générés pour Started, Succeeded et Failed.
- Les événements pour "detail-type":"Glue Scheduled Crawler Invocation Failure" sont générés lorsque le robot d'exploration planifié ne démarre pas. Voici les informations figurant dans la notification :

- `customerId` contient l'identifiant de compte du client.
- `crawlerName` contient le nom du robot d'exploration qui n'a pas pu démarrer.
- `errorMessage` contient le message d'exception signalant l'échec de l'invocation.
- Des événements pour `"detail_type": "Glue Auto Statistics Invocation Failure"` sont générés lorsque la tâche de statistiques de colonne gérée automatiquement exécutée ne démarre pas. Voici les informations figurant dans la notification :
 - `catalogId` contient l'ID associé à un catalogue.
 - `databaseName` contient le nom de la base de données concernée.
 - `tableName` contient le nom de la table concernée.
 - `errorMessage` contient le message d'exception signalant l'échec de l'invocation.
- Les événements pour `"detail_type": "Glue Scheduled Statistics Invocation Failure"` sont générés lorsque la tâche de statistiques de colonnes planifiée (cron) exécutée ne démarre pas. Voici les informations figurant dans la notification :
 - `catalogId` contient l'ID associé à un catalogue.
 - `databaseName` contient le nom de la base de données concernée.
 - `tableName` contient le nom de la table concernée.
 - `errorMessage` contient le message d'exception signalant l'échec de l'invocation.
- Les événements pour `"detail_type": "Glue Statistics Task Started"` sont générés lorsque l'exécution de la tâche de statistiques sur les colonnes démarre.
- Les événements pour `"detail_type": "Glue Statistics Task Succeeded"` sont générés lorsque l'exécution de la tâche de statistiques sur les colonnes aboutit.
- Les événements pour `"detail_type": "Glue Statistics Task Failed"` sont générés lorsque l'exécution de la tâche de statistiques sur les colonnes échoue.
- Les événements pour `"detail-type": "Glue Data Catalog Database State Change"` sont générés pour `CreateDatabase`, `DeleteDatabase`, `CreateTable`, `DeleteTable` et `BatchDeleteTable`. Par exemple, si une table est créée ou supprimée, une notification est envoyée à EventBridge. Notez que vous ne pouvez pas écrire un programme en fonction de la présence d'événements de notification ou de leur ordre, car il peut ne pas y en avoir ou ils peuvent ne pas être dans l'ordre défini. Les événements sont générés dans la mesure du possible. Voici les informations figurant dans la notification :
 - Le champ `typeOfChange` contient le nom de l'opération d'API.
 - Le champ `databaseName` indique le nom de la base de données concernée.

- Le champ `changedTables` contient jusqu'à 100 noms de tables concernées par notification. Lorsque les noms de table sont longs, plusieurs notifications peuvent être créées.
- Les événements pour `"detail-type": "Glue Data Catalog Table State Change"` sont générés pour `UpdateTable`, `CreatePartition`, `BatchCreatePartition`, `UpdatePartition`, `DeletePartition`, `BatchUpdatePartition` et `BatchDeletePartition`. Par exemple, si une table ou une partition est mise à jour, une notification est envoyée à EventBridge. Notez que vous ne pouvez pas écrire un programme en fonction de la présence d'événements de notification ou de leur ordre, car il peut ne pas y en avoir ou ils peuvent ne pas être dans l'ordre défini. Les événements sont générés dans la mesure du possible. Voici les informations figurant dans la notification :
 - Le champ `typeOfChange` contient le nom de l'opération d'API.
 - Le champ `databaseName` indique le nom de la base de données dont les ressources sont concernées.
 - Le champ `tableName` indique le nom de la table concernée.
 - Le champ `changedPartitions` spécifie jusqu'à 100 partitions concernées dans une notification. Lorsque les noms de partition sont longs, plusieurs notifications peuvent être créées.

Par exemple, s'il existe deux clés de partition, `Year` et `Month`, alors `"2018,01"`, `"2018,02"` modifie la partition si `"Year=2018"` and `"Month=01"` et si `"Year=2018"` and `"Month=02"`.

```
{
  "version": "0",
  "id": "abcdef00-1234-5678-9abc-def012345678",
  "detail-type": "Glue Data Catalog Table State Change",
  "source": "aws.glue",
  "account": "123456789012",
  "time": "2017-09-07T18:57:21Z",
  "region": "us-west-2",
  "resources": ["arn:aws:glue:us-west-2:123456789012:database/default/foo"],
  "detail": {
    "changedPartitions": [
      "2018,01",
      "2018,02"
    ],
    "databaseName": "default",
    "tableName": "foo",
    "typeOfChange": "BatchCreatePartition"
  }
}
```

```
}  
}
```

Pour plus d'informations, consultez le [guide de l'utilisateur Amazon CloudWatch Events](#). Pour les événements spécifiques à AWS Glue, voir [AWS Glue Évènements](#).

AWS Glue Ressources de surveillance

AWS Glue impose des limites de service afin de protéger les clients contre les approvisionnements excessifs inattendus et contre les actions malveillantes visant à augmenter votre facture. Les limites protègent également le service. En se connectant à la console AWS Service Quota, les clients peuvent consulter leurs limites de ressources actuelles et demander une augmentation (le cas échéant).

AWS Glue vous permet de visualiser l'utilisation des ressources du service sous forme de pourcentage dans Amazon CloudWatch et de configurer des CloudWatch alarmes pour surveiller l'utilisation. Amazon CloudWatch assure la surveillance des AWS ressources et des applications client exécutées sur l'infrastructure Amazon. Les métriques sont gratuites pour vous. Les métriques suivantes sont prises en charge :

- Nombre de flux de travail par compte
- Nombre de déclencheurs par compte
- Nombre de tâches par compte
- Nombre d'exécutions de tâches simultanées par compte
- Nombre de plans par compte
- Nombre de sessions interactives par compte


Configuration et utilisation des métriques de ressources

Pour utiliser cette fonctionnalité, vous pouvez accéder à la CloudWatch console Amazon pour consulter les statistiques et configurer les alarmes. Les métriques se trouvent sous l'espace de noms AWS/Glue et représentent un pourcentage du nombre réel d'utilisation des ressources divisé par le quota de ressources. Les CloudWatch statistiques sont transmises à vos comptes, sans frais pour vous. Par exemple, si vous avez créé 10 flux de travail et que votre quota de service vous permet d'avoir 200 flux de travail au maximum, votre utilisation est de $10/200 = 5\%$, et dans le graphique, vous verrez un point de données de cinq en tant que pourcentage. Pour être plus précis :

```

Namespace: AWS/Glue
Metric name: ResourceUsage
Type: Resource
Resource: Workflow (or Trigger, Job, JobRun, Blueprint, InteractiveSession)
Service: Glue
Class: None

```



Pour créer une alarme sur une métrique dans la CloudWatch console, procédez comme suit :

1. Une fois que vous avez localisé la métrique, accédez à Métriques graphiques.
2. Cliquez sur Créer une alarme sous Actions.
3. Configurez l'alarme selon vos besoins.

Nous émettons des métriques chaque fois que l'utilisation de vos ressources change (augmentation ou diminution, par exemple). Mais si l'utilisation de vos ressources ne change pas, nous émettons des métriques toutes les heures, afin que vous disposiez d'un CloudWatch graphique continu. Pour éviter d'avoir des points de données manquants, nous vous déconseillons de configurer une période inférieure à une heure.

Vous pouvez également configurer les alarmes à AWS CloudFormation l'aide de l'exemple suivant. Dans cet exemple, une fois que l'utilisation des ressources du flux de travail atteint 80 %, une alarme est déclenchée pour envoyer un message à la rubrique SNS existante, à laquelle vous pouvez vous abonner pour recevoir des notifications.

```
{
  "Type": "AWS::CloudWatch::Alarm",
  "Properties": {
    "AlarmName": "WorkflowUsageAlarm",
    "ActionsEnabled": true,
    "OKActions": [],
    "AlarmActions": [
      "arn:aws:sns:af-south-1:085425700061:Default_CloudWatch_Alarms_Topic"
    ],
    "InsufficientDataActions": [],
    "MetricName": "ResourceUsage",
    "Namespace": "AWS/Glue",
    "Statistic": "Maximum",
    "Dimensions": [{
      "Name": "Type",
      "Value": "Resource"
    },
    {
      "Name": "Resource",
      "Value": "Workflow"
    },
    {
      "Name": "Service",
      "Value": "Glue"
    },
    {
      "Name": "Class",
      "Value": "None"
    }
  ],
  "Period": 3600,
  "EvaluationPeriods": 1,
  "DatapointsToAlarm": 1,
  "Threshold": 80,
  "ComparisonOperator": "GreaterThanThreshold",
  "TreatMissingData": "notBreaching"
}
```


Journalisation AWS Glue Appels d'API avec AWS CloudTrail

AWS Glue est intégré à AWS CloudTrail un service qui fournit un enregistrement des actions entreprises par un utilisateur, un rôle ou un AWS service dans AWS Glue. CloudTrail capture tous les appels d'API pour AWS Glue en tant qu'événements. Les appels capturés incluent les appels provenant du AWS Glue appels de console et de code vers le AWS Glue Opérations d'API. Si vous créez un suivi, vous pouvez activer la diffusion continue d' CloudTrail événements vers un compartiment Amazon S3, y compris des événements pour AWS Glue. Si vous ne configurez pas de suivi, vous pouvez toujours consulter les événements les plus récents dans la CloudTrail console dans Historique des événements. À l'aide des informations collectées par CloudTrail, vous pouvez déterminer la demande qui a été faite à AWS Glue, l'adresse IP à partir de laquelle la demande a été faite, l'auteur de la demande, la date à laquelle elle a été faite et des informations supplémentaires.

Pour en savoir plus CloudTrail, consultez le [guide de AWS CloudTrail l'utilisateur](#).

AWS Glue informations dans CloudTrail

CloudTrail est activé sur votre AWS compte lorsque vous le créez. Lorsque l'activité se produit dans AWS Glue, cette activité est enregistrée dans un CloudTrail événement avec d'autres événements de AWS service dans l'historique des événements. Vous pouvez consulter, rechercher et télécharger les événements récents dans votre AWS compte. Pour plus d'informations, consultez la section [Affichage des événements avec l'historique des CloudTrail événements](#).

Pour un enregistrement continu des événements de votre AWS compte, y compris les événements pour AWS Glue, créez un parcours. Un suivi permet CloudTrail de fournir des fichiers journaux à un compartiment Amazon S3. Par défaut, lorsque vous créez un parcours dans la console, celui-ci s'applique à toutes les AWS régions. Le journal enregistre les événements de toutes les régions de la AWS partition et transmet les fichiers journaux au compartiment Amazon S3 que vous spécifiez. En outre, vous pouvez configurer d'autres AWS services pour analyser plus en détail les données d'événements collectées dans les CloudTrail journaux et agir en conséquence. Pour plus d'informations, consultez les ressources suivantes :

- [Création d'un parcours pour votre AWS compte](#)
- [CloudTrail services et intégrations pris en charge](#)
- [Configuration des notifications Amazon SNS pour CloudTrail](#)
- [Réception de fichiers CloudTrail journaux de plusieurs régions](#) et [réception de fichiers CloudTrail journaux de plusieurs comptes](#)

Tous AWS Glue les actions sont enregistrées CloudTrail et documentées dans le [AWS Glue API](#). Par exemple, les appels au `CreateDatabase` `CreateTable` et les `CreateScript` actions génèrent des entrées dans les fichiers CloudTrail journaux.

Chaque événement ou entrée de journal contient des informations sur la personne ayant initié la demande. Les informations relatives à l'identité permettent de déterminer les éléments suivants :

- Si la demande a été effectuée avec des informations d'identification d'utilisateur root ou IAM.
- Si la demande a été effectuée avec des informations d'identification de sécurité temporaires pour un rôle ou un utilisateur fédéré.
- Si la demande a été faite par un autre AWS service.

Pour plus d'informations, consultez la section [Élément `userIdentity` CloudTrail](#).

Cependant, CloudTrail n'enregistre pas toutes les informations concernant les appels. Par exemple, il n'enregistre pas certaines informations sensibles, telles que celles `ConnectionProperties` utilisées dans les demandes de connexion, et il enregistre un `null` au lieu des réponses renvoyées par les éléments suivants APIs :

<code>BatchGetPartition</code>	<code>GetCrawlers</code>	<code>GetJobs</code>	<code>GetTable</code>
<code>CreateScript</code>	<code>GetCrawlerMetrics</code>	<code>GetJobRun</code>	<code>GetTables</code>
<code>GetCatalogImportStatus</code>	<code>GetDatabase</code>	<code>GetJobRuns</code>	<code>GetTableVersions</code>
<code>GetClassifier</code>	<code>GetDatabases</code>	<code>GetMapping</code>	<code>GetTrigger</code>
<code>GetClassifiers</code>	<code>GetDataflowGraph</code>	<code>GetObjects</code>	<code>GetTriggers</code>
<code>GetConnection</code>	<code>GetDevEndpoint</code>	<code>GetPartition</code>	<code>GetUserDefinedFunction</code>
<code>GetConnections</code>	<code>GetDevEndpoints</code>	<code>GetPartitions</code>	<code>GetUserDefinedFunctions</code>
<code>GetCrawler</code>	<code>GetJob</code>	<code>GetPlan</code>	

Compréhension AWS Glue entrées du fichier journal

Un suivi est une configuration qui permet de transmettre des événements sous forme de fichiers journaux à un compartiment Amazon S3 que vous spécifiez. CloudTrail les fichiers journaux contiennent une ou plusieurs entrées de journal. Un événement représente une demande unique provenant de n'importe quelle source et inclut des informations sur l'action demandée, la date et l'heure de l'action, les paramètres de la demande, etc. CloudTrail les fichiers journaux ne constituent pas une trace ordonnée des appels d'API publics, ils n'apparaissent donc pas dans un ordre spécifique.

L'exemple suivant montre une entrée de CloudTrail journal illustrant l'`DeleteCrawler` action.

```
{
  "eventVersion": "1.05",
  "userIdentity": {
    "type": "IAMUser",
    "principalId": "AKIAIOSFODNN7EXAMPLE",
    "arn": "arn:aws:iam::123456789012:user/johndoe",
    "accountId": "123456789012",
    "accessKeyId": "AKIAIOSFODNN7EXAMPLE",
    "userName": "johndoe"
  },
  "eventTime": "2017-10-11T22:29:49Z",
  "eventSource": "glue.amazonaws.com",
  "eventName": "DeleteCrawler",
  "awsRegion": "us-east-1",
  "sourceIPAddress": "72.21.198.64",
  "userAgent": "aws-cli/1.11.148 Python/3.6.1 Darwin/16.7.0 boto3/1.7.6",
  "requestParameters": {
    "name": "tes-alpha"
  },
  "responseElements": null,
  "requestID": "b16f4050-aed3-11e7-b0b3-75564a46954f",
  "eventID": "e73dd117-cfd1-47d1-9e2f-d1271cad838c",
  "eventType": "AwsApiCall",
  "recipientAccountId": "123456789012"
}
```

Cet exemple montre une entrée de CloudTrail journal illustrant une `CreateConnection` action.

```
{
  "eventVersion": "1.05",
  "userIdentity": {
    "type": "IAMUser",
    "principalId": "AKIAIOSFODNN7EXAMPLE",
    "arn": "arn:aws:iam::123456789012:user/johndoe",
    "accountId": "123456789012",
    "accessKeyId": "AKIAIOSFODNN7EXAMPLE",
    "userName": "johndoe"
  },
  "eventTime": "2017-10-13T00:19:19Z",
  "eventSource": "glue.amazonaws.com",
  "eventName": "CreateConnection",
  "awsRegion": "us-east-1",
  "sourceIPAddress": "72.21.198.66",
```

```
"userAgent": "aws-cli/1.11.148 Python/3.6.1 Darwin/16.7.0 botocore/1.7.6",
"requestParameters": {
  "connectionInput": {
    "name": "test-connection-alpha",
    "connectionType": "JDBC",
    "physicalConnectionRequirements": {
      "subnetId": "subnet-323232",
      "availabilityZone": "us-east-1a",
      "securityGroupIdList": [
        "sg-12121212"
      ]
    }
  }
},
"responseElements": null,
"requestID": "27136ebc-afac-11e7-a7d6-ab217e5c3f19",
"eventID": "e8b3baeb-c511-4597-880f-c16210c60a4a",
"eventType": "AwsApiCall",
"recipientAccountId": "123456789012"
}
```

AWS Glue états d'exécution des tâches

Vous pouvez consulter le statut d'un AWS Glue tâche d'extraction, de transformation et de chargement (ETL) pendant son exécution ou après son arrêt. Vous pouvez consulter le statut à l'aide du AWS Glue console, le AWS Command Line Interface (AWS CLI) ou l'[GetJobRunaction](#) dans le AWS Glue API.

Les états d'exécution de tâche possibles sont STARTING, RUNNING, STOPPING, STOPPED, SUCCEEDED, FAILED, ERROR, WAITING et TIMEOUT.

Le tableau suivant répertorie les états qui indiquent une fin de tâche anormale.

Statut d'exécution de la tâche	Description
FAILED	La tâche a dépassé son nombre maximal autorisé d'exécutions simultanées ou s'est terminée avec un code de sortie inconnu.


Statut d'exécution de la tâche	Description
ERROR	Un flux de travail, un déclencheur de planification ou un déclencheur d'événement a tenté d'exécuter une tâche supprimée.
TIMEOUT	Le temps d'exécution de la tâche a dépassé sa valeur de délai d'expiration spécifiée.
WAITING	Une tâche exécutée en attente de ressources.

L'état WAITING indique qu'une exécution de tâche attend des ressources. La table suivante décrit le comportement d'attente pour différentes catégories de tâches.

Type de tâche	Attitude
Des tâches Spark (Standard)	Les tâches peuvent passer à l'état WAITING si vous optez pour la mise en file d'attente des tâches AWS Glue, comme décrit dans Configuration des propriétés des tâches pour les tâches Spark dans AWS Glue. Une tâche est peut-être en attente car les quotas de service pour votre compte ou les limites de capacité dans votre région se heurtent à l'un des cas d'erreur suivants : • Dépassement du nombre maximal de tâches simultanées par compte • Nombre maximum d'exécutions simultanées par tâche dépassée (inclut le quota de service au niveau du compte ainsi que la limite que vous spécifiez pour la tâche avec <code>MaxConcurrentRuns</code>) • Nombre maximal de calculs simultanés (utilisation de la DPU) dépassé • Ressource non disponible

Type de tâche	Attitude
	Les tâches peuvent également être mises en attente si les ressources sont insuffisantes pour démarrer leur exécution, quels que soient les quotas de service.
Des tâches Spark (Flex)	Une nouvelle exécution de tâche sera dans l'état WAITING si le service n'est pas en mesure d'acquérir suffisamment de ressources pour démarrer l'exécution, ce qui retarde le démarrage de l'exécution. L'exécution sera en état WAITING pendant 20 minutes maximum (délai d'attente contrôlé par le service). Après 15 minutes, le service essaiera d'effectuer un démarrage forcé et, en fonction de la capacité disponible, l'exécution peut démarrer ou échouer avec un message d'erreur correspondant.
Tâches shell Python	Même comportement que les tâches standard utilisant Spark.

Le diagramme d'état suivant décrit les transitions d'état attendues tout au long du cycle de vie d'une tâche AWS Glue. Ces informations s'appliquent à tous les types d'emplois.



AWS Glue Streaming

AWS Glue Le streaming, un composant de AWS Glue, vous permet de gérer efficacement les données en streaming en temps quasi réel, ce qui vous permet d'effectuer des tâches cruciales telles que l'ingestion, le traitement et l'apprentissage automatique des données. Grâce au framework Apache Spark Streaming, AWS Glue Streaming fournit un service sans serveur capable de gérer les données de streaming à grande échelle. AWS Glue fournit diverses optimisations en plus d'Apache Spark, telles que l'infrastructure sans serveur, l'auto-scaling, le développement visuel des tâches, les blocs-notes instantanés pour les tâches de streaming et d'autres améliorations de performances.

Cas d'utilisation pour le streaming

Parmi les cas d'utilisation courants du AWS Glue streaming, citons :

Near-real-time traitement des données : le AWS Glue streaming permet aux entreprises de traiter les données en streaming en temps quasi réel, ce qui leur permet d'en tirer des informations et de prendre des décisions en temps opportun sur la base des informations les plus récentes.

Détection des fraudes : vous pouvez utiliser le AWS Glue streaming pour analyser en temps réel les données de streaming, ce qui le rend utile pour détecter les activités frauduleuses, telles que les fraudes par carte de crédit, les intrusions sur le réseau ou les escroqueries en ligne. En traitant et en analysant en permanence les données entrantes, vous pouvez rapidement identifier les schémas suspects ou les anomalies.

Analyse des réseaux sociaux : le AWS Glue streaming peut traiter les données des réseaux sociaux en temps réel, telles que les tweets, les publications ou les commentaires, permettant aux entreprises de suivre les tendances, d'analyser les sentiments et de gérer la réputation de la marque en temps réel.

Analyse de l'Internet des objets (IoT) : le AWS Glue streaming convient à la gestion et à l'analyse de flux de données à haute vitesse générés par des appareils IoT, des capteurs et des machines connectées. Il permet le suivi en temps réel, la détection des anomalies, la maintenance prédictive et d'autres cas d'utilisation de l'analytique IoT.

Analyse du flux de clics : le AWS Glue streaming peut traiter et analyser les données du flux de clics en temps réel provenant de sites Web ou d'applications mobiles. Cela permet aux entreprises de mieux comprendre le comportement des utilisateurs, de personnaliser les expériences utilisateur et d'optimiser les campagnes marketing en fonction des données du flux de clics en temps réel.

Surveillance et analyse des journaux : le AWS Glue streaming permet de traiter et d'analyser en continu les données des journaux provenant de serveurs, d'applications ou de périphériques réseau en temps réel. Cela permet de détecter les anomalies, de résoudre les problèmes et de surveiller l'état et les performances du système.

Systèmes de recommandation : le AWS Glue streaming peut traiter les données d'activité des utilisateurs en temps réel et mettre à jour les modèles de recommandation de manière dynamique. Cela permet des recommandations personnalisées et en temps réel basées sur le comportement et les préférences des utilisateurs.

Voici quelques exemples de la diversité des cas d'utilisation dans lesquels le AWS Glue streaming peut être appliqué. Son intégration à l' AWS écosystème et aux services gérés en fait un choix pratique pour le traitement et l'analyse des flux en temps réel dans le cloud.

Quels sont les avantages du AWS Glue streaming ?

Les avantages de l'utilisation du AWS Glue streaming sont les suivants :

- Sans serveur : le AWS Glue streaming se fait sans serveur, ce qui élimine le besoin de gérer l'infrastructure. Cela réduit les frais opérationnels et permet aux utilisateurs de se concentrer sur les tâches de traitement et d'analytique des données plutôt que sur la gestion de l'infrastructure.
- Mise à l'échelle automatique : le AWS Glue streaming fournit des fonctionnalités de mise à l'échelle automatique, ajustant dynamiquement la capacité de traitement en fonction de la charge de travail. Il monte en puissance ou se met à l'échelle horizontale automatiquement pour gérer les fluctuations du volume de données, garantissant ainsi des performances et une utilisation des ressources optimales.
- Développement visuel : le développement des emplois en streaming peut être complexe. AWS Glue Le streaming répond à ce défi en proposant AWS Glue Studio, un outil de création visuelle. AWS Glue Studio simplifie le processus de création de flux de travail de streaming et permet aux développeurs de concevoir et de gérer visuellement des applications de streaming, réduisant ainsi la courbe d'apprentissage et augmentant la productivité.
- Rentable : en tant que service sans serveur, le AWS Glue streaming permet de réduire les coûts en éliminant le besoin de provisionnement et de maintenance de l'infrastructure. Les utilisateurs sont facturés en fonction des ressources consommées lors de l'exécution des tâches de streaming, ce qui permet une optimisation des coûts et une mise à l'échelle en fonction de l'utilisation réelle.
- Gère des charges de travail complexes : le AWS Glue streaming est conçu pour gérer des charges de travail de streaming complexes. Il peut traiter et analyser de grands volumes de données

en temps réel, prendre en charge des transformations avancées et s'intégrer à d'autres AWS services, permettant ainsi des pipelines de données en streaming et des flux de travail d'analyse sophistiqués.

- **Aucune dépendance** : le AWS Glue streaming apporte de la flexibilité et évite la dépendance vis-à-vis d'un fournisseur. Les utilisateurs peuvent tirer parti du AWS Glue streaming dans le cadre d'un AWS écosystème plus large, en l'intégrant parfaitement à d'autres AWS services. Cela permet une intégration facile avec les sources de données, les applications et les services existants sans être lié à une technologie ou à une plateforme spécifique.

Quand utiliser le AWS Glue streaming ?

Il existe de nombreuses options en ce qui concerne les cas d'utilisation du streaming. Nous recommandons le AWS Glue streaming dans les scénarios suivants.

1. Si vous utilisez AWS Glue déjà Spark pour le traitement par lots, AWS Glue Streaming est le choix idéal pour vous. Il permet une transition fluide vers la création de tâches de streaming sans qu'il soit nécessaire d'apprendre un nouveau langage ou un nouveau cadre. En tirant parti de vos connaissances et de votre infrastructure existantes, AWS Glue Streaming simplifie le processus de développement des tâches et vous permet d'étendre facilement vos capacités de traitement des données à des scénarios de streaming en temps réel.
2. Si vous avez besoin d'un service ou d'un produit unifié pour gérer les charges de travail par lots, de streaming et d'événements, AWS Glue Streaming est la solution qu'il vous faut. Grâce au AWS Glue streaming, vous pouvez regrouper vos besoins en matière de traitement des données dans un cadre unique, éliminant ainsi la complexité liée à la gestion de plusieurs systèmes. Cela permet le développement et la maintenance efficaces de divers flux de données tout en garantissant la cohérence et la compatibilité entre les différents types de charge de travail.
3. AWS Glue Le streaming convient parfaitement aux scénarios impliquant des volumes de données en streaming extrêmement importants et des transformations complexes, telles que des jointures entre des flux ou des bases de données relationnelles. Il peut traiter et analyser efficacement des flux de données massifs, ce qui vous permet de gérer facilement des charges de travail exigeantes. Qu'il s'agisse d'une ingestion de données à grande vitesse ou de manipulations de données complexes, l'évolutivité et les capacités de traitement avancées du AWS Glue streaming garantissent des performances optimales et des résultats précis.
4. Si vous préférez une approche visuelle pour créer des jobs de streaming, Studio vous AWS Glue propose AWS Glue Studio, avec lequel vous pouvez concevoir et gérer visuellement vos applications de streaming, simplifiant ainsi le processus de développement. Cette interface intuitive

permet aux développeurs de créer, configurer et surveiller les flux de travail de streaming à l'aide d'une interface visuelle, réduisant ainsi la courbe d'apprentissage et augmentant la productivité.

5. AWS Glue Le streaming est un excellent choix pour les cas near-real-time d'utilisation où des accords de niveau de service stricts SLAs (accords de niveau de service) sont supérieurs à 10 secondes.
6. Si vous créez un lac de données transactionnel à l'aide d'Apache Iceberg, Apache Hudi ou Delta Lake, AWS Glue Streaming fournit un support natif pour ces formats de table ouverts. Cette intégration fluide vous permet de traiter les données de streaming directement à partir de ces lacs de données transactionnels, garantissant ainsi la cohérence, l'intégrité et la compatibilité des données.
7. Lorsque vous devez ingérer des données de streaming pour diverses cibles de données : le AWS Glue streaming fournit des cibles natives à diverses cibles de données telles qu'Amazon Redshift, Amazon RDS, Amazon Aurora, Oracle, SQL Server et d'autres cibles.

Sources de données prises en charge

AWS Glue Le streaming prend en charge les sources de données suivantes :

- Amazon Kinesis
- Amazon MSK (Managed Streaming for Apache Kafka)
- Self-managed Apache Kafka

Cibles de données prises en charge

AWS Glue Le streaming prend en charge diverses cibles de données, telles que :

- Cibles de données prises en charge par AWS Glue Data Catalog
- Amazon S3
- Amazon Redshift
- MySQL
- PostgreSQL
- Oracle
- Microsoft SQL Server

- Snowflake
- Toute base de données pouvant être connectée à l'aide de JDBC
- Apache Iceberg, Delta et Apache Hudi
- AWS Glue Connecteurs Marketplace

Tutoriel : Créez votre première charge de travail de streaming à l'aide de AWS Glue Studio

Dans ce didacticiel, vous allez apprendre à créer une tâche de streaming à l'aide de AWS Glue Studio. AWS Glue Studio est une interface visuelle permettant de créer des AWS Glue emplois.

Vous pouvez créer des tâches d'extraction, de transformation et de chargement (ETL) en streaming qui s'exécutent en continu et consomment des données provenant de sources en streaming dans Amazon Kinesis Data Streams, Apache Kafka et Amazon Managed Streaming for Apache Kafka (Amazon MSK).

Prérequis

Pour suivre ce didacticiel, vous aurez besoin d'un utilisateur autorisé à utiliser AWS la console AWS Glue, Amazon Kinesis, Amazon S3, Amazon Athena AWS CloudFormation, AWS Lambda et Amazon Cognito.

Utilisation des données de streaming à partir d'Amazon Kinesis

Rubriques

- [Génération de données fictives avec Kinesis Data Generator](#)
- [Création d'une tâche de AWS Glue streaming avec AWS Glue Studio](#)
- [Exécution d'une transformation et stockage du résultat transformé dans Amazon S3](#)

Génération de données fictives avec Kinesis Data Generator

Vous pouvez générer des exemples de données de manière synthétique au format JSON à l'aide de Kinesis Data Generator (KDG). Vous trouverez des instructions complètes et des détails dans la [documentation de l'outil](#).

1. Pour commencer, cliquez



pour

exécuter un AWS CloudFormation modèle dans votre AWS environnement.

Note

Il se peut que le CloudFormation modèle ne fonctionne pas, car certaines ressources, telles que l'utilisateur Amazon Cognito pour Kinesis Data Generator, existent déjà dans votre compte. AWS Cela peut être dû au fait que vous l'avez déjà configuré à partir d'un autre didacticiel ou blog. Pour résoudre ce problème, vous pouvez soit essayer le modèle dans un nouveau AWS compte pour prendre un nouveau départ, soit explorer une autre AWS région. Ces options vous permettent d'exécuter le didacticiel sans entrer en conflit avec les ressources existantes.

Le modèle vous fournit un flux de données Kinesis et un compte Kinesis Data Generator. Il crée également un compartiment Amazon S3 pour contenir les données et une fonction du service Glue avec les autorisations requises pour ce didacticiel.

2. Saisissez un Nom d'utilisateur et un Mot de passe que le KDG utilisera pour s'authentifier. Notez le nom d'utilisateur et le mot de passe pour une utilisation ultérieure.
3. Sélectionnez Suivant jusqu'à la dernière étape. Reconnaissez la création de ressources IAM. Vérifiez les erreurs en haut de l'écran, par exemple un mot de passe ne répondant pas aux exigences minimales, et déployez le modèle.
4. Accédez à l'onglet Sorties de la pile. Une fois le modèle déployé, il affiche la propriété générée KinesisDataGeneratorUrl. Cliquez sur cette URL.
5. Saisissez le Nom d'utilisateur et le Mot de passe que vous avez notés.
6. Sélectionnez la région que vous utilisez et sélectionnez l'GlueStreamTest-`{AWS::AccountId}` de flux Kinesis.
7. Saisissez le modèle suivant :

```
{
  "ventilatorid": {{random.number(100)}},
  "eventtime": "{{date.now("YYYY-MM-DD HH:mm:ss")}}",
  "serialnumber": "{{random.uuid}}",
  "pressurecontrol": {{random.number(
    {
```

```

        "min":5,
        "max":30
    }
  }},
  "o2stats": {{random.number(
    {
      "min":92,
      "max":98
    }
  )}},
  "minutevolume": {{random.number(
    {
      "min":5,
      "max":8
    }
  )}},
  "manufacturer": "{{random.arrayElement(
    ["3M", "GE","Vyaire", "Getinge"]
  )}}"
}


```

Vous pouvez désormais afficher des données fictives avec Modèle de test et ingérer les données fictives dans Kinesis avec Envoyer des données.

8. Cliquez sur Envoyer des données et générez 5 000 à 10 000 enregistrements vers Kinesis.

Création d'une tâche de AWS Glue streaming avec AWS Glue Studio

1. Accédez AWS Glue à la console dans la même région.
2. Sélectionnez Tâches ETL dans la barre de navigation de gauche, sous Intégration de données et ETL.
3. Créez un AWS Glue Job via Visual avec un canevas vierge.



4. Accédez à l'onglet Détails de la tâche.
5. Pour le nom de la AWS Glue tâche, entrez `DemoStreamingJob`.

6. Pour le rôle IAM, sélectionnez le rôle fourni par le CloudFormation modèle, `glue-tutorial-role-${AWS::AccountId}`
7. Pour Version Glue, sélectionnez Glue 3.0. Conservez toutes valeurs par défaut des autres options.

Basic properties [Info](#)

Name

Description - optional

Descriptions can be up to 2048 characters long.

IAM Role
Role assumed by the job with permission to access your data stores. Ensure that this role has permission to your Amazon S3 sources, targets, temporary directory, scripts, and any libraries used by the job.





Type
The type of ETL job. This is set automatically based on the types of data sources you have selected.

Glue version [Info](#)
 


Language
 

Worker type
Set the type of predefined worker that is allowed when a job runs.


(4vCPU and 16GB RAM)

Automatically scale the number of workers
☐ AWS Glue will optimize costs and resource usage by dynamically scaling the number of workers up and down throughout the job run. Requires Glue 3.0 or later.

8. Accédez à l'onglet Visuel.
9. Cliquez sur l'icône plus. Saisissez Kinesis dans la barre de recherche. Sélectionnez la source de données Amazon Kinesis.



10. Sélectionnez Détails du flux pour Source Amazon Kinesis sous l'onglet Propriétés de la source de données – Flux Kinesis.
11. Sélectionnez Le flux se trouve sur mon compte pour Emplacement du flux de données.
12. Sélectionnez la région que vous utilisez.
13. Sélectionnez le flux `GlueStreamTest-{AWS::AccountId}`.
14. Conservez tous les autres paramètres par défaut.

Data source properties - Kinesis Stream
Output schema
Data preview

Name
Amazon Kinesis

Amazon Kinesis Source
Info
☒ Stream details
☐ Data Catalog table

Location of data stream
☒ Stream is located in my account
☐ Stream is located in another account

Region
US East (Ohio) us-east-2

Stream name
Info
GlueStreamTest-

Data format
JSON

Starting position
Select the position where the job will start reading from the input stream.
Earliest
Start reading from the oldest available record in the stream.

Window size
Info
Enter the time in seconds spent between batch calls.
100

15 Accédez à l'onglet Aperçu des données.

16 Cliquez sur Démarrer la session d'aperçu des données, qui affiche un aperçu des données fictives générées par KDG. Choisissez le rôle de service Glue que vous avez créé précédemment pour la tâche de AWS Glue streaming.

Il faut 30 à 60 secondes pour que les données d'aperçu s'affichent. Si Aucune donnée à afficher s'affiche, cliquez sur l'icône en forme de rouage et définissez Nombre de lignes à échantillonner sur 100.

Vous pouvez voir les exemples de données ci-dessous :

Data source properties - Kinesis Stream

Output schema

Data preview

Data preview (100) info

Filter sample dataset

Previewing 7 of 7 fields


eventtime	manufacturer	minutevolume	o2stats	pressurecontrol	serialnumber	ventilatorid
2023-06-26 14:25:37	Vyaire	5	95	7	9e79ae66-33a7-48e5-ab78-a61271199d5d	92
2023-06-26 14:25:37	3M	5	98	17	cfb845ca-b513-4c27-9543-74dd222fc537	10
2023-06-26 14:25:37	GE	8	98	23	90ba966c-6676-4567-a584-e267e714e57d	37
2023-06-26 14:25:37	Vyaire	8	92	16	77f78f41-be24-47dc-b25c-05428bd76a0b	56
2023-06-26 14:25:37	Getinge	6	92	23	ddf7b9e1-d0f7-4381-8aea-06a934583f5c	28
2023-06-26 14:25:37	Getinge	5	92	6	c3ca9991-9b97-43e7-a866-59acbc6c5b17	84
2023-06-26 14:25:37	3M	8	98	21	93c49e41-868b-4b5b-b725-06b4b1fb0a09	68
2023-06-26 14:25:37	Vyaire	8	92	18	e46abe8d-b02f-43e6-91bf-c4700719f846	10
2023-06-26 14:25:37	Vyaire	8	93	16	b3946e38-6292-4afd-8695-ada5cc09d0dd	15
2023-06-26 14:25:37	GE	8	93	10	e3f7390d-1e68-4def-9dae-5c98b1d85d9d	3
2023-06-26 14:25:37	Vyaire	8	98	17	a3917233-fe7f-4105-8728-779bd7ab1379	8
2023-06-26 14:25:37	Getinge	8	98	16	06a8e8ff-cae4-4438-9714-33324f1524c9	93
2023-06-26 14:25:37	Getinge	6	96	14	7af06237-bbdf-4615-b9ac-05d05d484ba0	13
2023-06-26 14:25:37	3M	8	93	8	bf9985f6-04b8-442b-b7f9-24b1db6b5a37	81
2023-06-26 14:25:37	Getinge	6	97	28	e67f4220-3070-4951-b4e0-c86b7489de10	19
2023-06-26 14:25:37	3M	6	92	15	77954206-535e-4ef8-a1fe-0da5ece049a6	31
2023-06-26 14:25:37	Vyaire	7	94	25	81303a43-6206-46cb-851f-fc3986491bf9	32

Vous pouvez également voir le schéma déduit dans l'onglet Schéma de sortie.

Data source properties - Kinesis Stream		Output schema	Data preview
Schema ⓘ			
Key			Data type
eventtime			string
manufacturer			string
minutevolume			long
o2stats			long
pressurecontrol			long
serialnumber			string
ventilatorid			long

Exécution d'une transformation et stockage du résultat transformé dans Amazon S3

1. Une fois le nœud source sélectionné, cliquez sur l'icône plus en haut à gauche pour ajouter une étape Transformations.
2. Sélectionnez l'étape Modifier le schéma.



3. Vous pouvez renommer les champs et convertir le type de données des champs au cours de cette étape. Renommez la colonne `o2stats` en `OxygenSaturation` et convertissez tous les types de données `long` en `int`.

Transform

Output schema

Data preview

Name

Change Schema

Node parents

Choose which nodes will provide inputs for this one.

Choose one or more parent node

Amazon Kinesis


X

Kinesis - DataSource

Change Schema (Apply mapping)

Source key	Target key	Data type	Drop
eventtime	eventtime	string	☐
manufacturer	manufacturer	string	☐
minutevolume	minutevolume	int	☐
o2stats	OxygenSaturation	int	☐
pressurecontrol	pressurecontrol	int	☐
serialnumber	serialnumber	string	☐
ventilatorid	ventilatorid	int	☐

4. Cliquez sur l'icône plus pour ajouter une cible Amazon S3. Saisissez S3 dans le champ de recherche et sélectionnez l'étape de transformation Amazon S3 – Cible.



5. Sélectionnez Parquet comme format de fichier cible.
6. Sélectionnez Snappy comme type de compression.
7. Entrez un emplacement cible S3 créé par le CloudFormation modèle, `streaming-tutorial-s3-target-{AWS::AccountId}`.
8. Sélectionnez Créer une table dans le catalogue de données et lors des exécutions suivantes, mettre à jour le schéma et ajouter de nouvelles partitions.
9. Saisissez la Base de données cible et le nom de la Table pour stocker le schéma de la table cible Amazon S3.

Name

Amazon S3

Node parents

Choose which nodes will provide inputs for this one.

Choose one or more parent node

Change Schema



ApplyMapping - Transform

Format

Parquet

Compression Type

Snappy

S3 Target Location

Choose an S3 location in the format s3://bucket/prefix/object/ with a trailing slash (/).

s3://



View

Browse S3

Data Catalog update options [Info](#)

Choose how you want to update the Data Catalog table's schema and partitions. These options will only apply if the Data Catalog table is an S3 backed source.

- ☐ Do not update the Data Catalog
- ☒ Create a table in the Data Catalog and on subsequent runs, update the schema and add new partitions
- ☐ Create a table in the Data Catalog and on subsequent runs, keep existing schema and add new partitions

Database

Choose the database from the AWS Glue Data Catalog.

demo



Use runtime parameters

Table name

Enter a table name for the AWS Glue Data Catalog.

demo_stream_transform_result

10. Cliquez sur l'onglet Script pour afficher le code généré.

11. Cliquez sur Enregistrer en haut à droite pour enregistrer le code ETL, puis sur Exécuter pour lancer la tâche de AWS Glue streaming.

Vous pouvez trouver le Statut d'exécution dans l'onglet Exécutions. Laissez la tâche s'exécuter pendant trois à cinq minutes, puis arrêtez-la.

Visual	Script	Job details	Runs	Data quality New	Schedules	Version Control
Job runs (1/1) Info Filter job runs by property						
Run status	Retry	Start time	End time	Duration		
Running	0	06/26/2023 15:58:05	-	35 s		

12. Vérifiez la nouvelle table créée dans Amazon Athena.

Query 9 :

1

select * from "demo_stream_transform_result"

SQL Ln 1, Col 45

Run again

Explain

Cancel

Clear

Create

Reuse query results

up to 60 minutes ago

Query results

Query stats

Completed

Time in queue: 137 ms Run time: 894 ms Data scanned: 91.59 KB

Results (2,200)

Copy

Download results

Search rows

#	eventtime	manufacture	minutevolume	oxygensaturatio	pressurecontro	serialnumber	ventilatori	ingest_year	ingest_mont	ingest_day
13	2023-06-26 16:03:24	Vyair	6	98	10	8e438321-3bee-423f-9bcd-c693ee475868	91	2023	06	26
17	2023-06-26 16:03:24	3M	5	98	17	a7bcb332-6c52-489e-9a55-c923f3f650d2	64	2023	06	26
19	2023-06-26 16:03:24	Getinge	7	98	24	871a5ed3-4912-4b51-8428-5cb3e1d0034a	30	2023	06	26
27	2023-06-26 16:04:24	Vyair	8	98	8	5e4eeeba-29bb-4add-9013-2307c640b09e	94	2023	06	26
29	2023-06-26 16:04:24	3M	7	98	26	69443bbd-f347-419a-97d0-912cb88b36eb	3	2023	06	26
31	2023-06-26 16:04:24	3M	7	98	16	9d6242e6-7f57-48a4-bbb6-3e1b954454be	8	2023	06	26

Tutoriel : créez votre première charge de travail de streaming à l'aide des blocs-notes AWS Glue Studio

Dans ce didacticiel, vous découvrirez comment tirer parti des blocs-notes AWS Glue Studio pour créer et affiner de manière interactive vos tâches ETL pour le traitement des données en temps quasi réel. Que vous débutiez AWS Glue ou que vous souhaitiez améliorer vos compétences, ce guide vous guidera tout au long du processus et vous permettra d'exploiter tout le potentiel des carnets de session AWS Glue interactifs.

Avec AWS Glue Streaming, vous pouvez créer des tâches d'extraction, de transformation et de chargement (ETL) exécutées en continu et consommant des données provenant de sources de streaming telles qu'Amazon Kinesis Data Streams, Apache Kafka et Amazon Managed Streaming for Apache Kafka (Amazon MSK).

Prérequis

Pour suivre ce didacticiel, vous aurez besoin d'un utilisateur autorisé à utiliser AWS la console AWS Glue, Amazon Kinesis, Amazon S3, Amazon Athena AWS CloudFormation, AWS Lambda et Amazon Cognito.

Utilisation des données de streaming à partir d'Amazon Kinesis

Rubriques

- [Génération de données fictives avec Kinesis Data Generator](#)
- [Création d'une tâche de AWS Glue streaming avec AWS Glue Studio](#)
- [Nettoyage](#)
- [Conclusion](#)

Génération de données fictives avec Kinesis Data Generator

Note

Si vous avez déjà terminé le précédent [Tutoriel : Créez votre première charge de travail de streaming à l'aide de AWS Glue Studio](#), Kinesis Data Generator est déjà installé sur votre compte et vous pouvez ignorer les étapes 1 à 8 ci-dessous et passer à la section [Création d'une tâche de AWS Glue streaming avec AWS Glue Studio](#).

Vous pouvez générer des exemples de données de manière synthétique au format JSON à l'aide de Kinesis Data Generator (KDG). Vous trouverez des instructions complètes et des détails dans la [documentation de l'outil](#).

1. Pour commencer, cliquez



_____ pour
exécuter un AWS CloudFormation modèle dans votre AWS environnement.

 Note

Il se peut que le CloudFormation modèle ne fonctionne pas, car certaines ressources, telles que l'utilisateur Amazon Cognito pour Kinesis Data Generator, existent déjà dans votre compte. AWS Cela peut être dû au fait que vous l'avez déjà configuré à partir d'un autre didacticiel ou blog. Pour résoudre ce problème, vous pouvez soit essayer le modèle dans un nouveau AWS compte pour prendre un nouveau départ, soit explorer une autre AWS région. Ces options vous permettent d'exécuter le didacticiel sans entrer en conflit avec les ressources existantes.

Le modèle vous fournit un flux de données Kinesis et un compte Kinesis Data Generator.

2. Saisissez un Nom d'utilisateur et un Mot de passe que le KDG utilisera pour s'authentifier. Notez le nom d'utilisateur et le mot de passe pour une utilisation ultérieure.
3. Sélectionnez Suivant jusqu'à la dernière étape. Reconnaissez la création de ressources IAM. Vérifiez les erreurs en haut de l'écran, par exemple un mot de passe ne répondant pas aux exigences minimales, et déployez le modèle.
4. Accédez à l'onglet Sorties de la pile. Une fois le modèle déployé, il affiche la propriété générée `KinesisDataGeneratorUrl`. Cliquez sur cette URL.
5. Saisissez le Nom d'utilisateur et le Mot de passe que vous avez notés.
6. Sélectionnez la région que vous utilisez et sélectionnez l'`GlueStreamTest-{AWS::AccountId}` de flux Kinesis.
7. Saisissez le modèle suivant :

```
{
  "ventilatorid": {{random.number(100)}},
  "eventtime": "{{date.now("YYYY-MM-DD HH:mm:ss")}}",
  "serialnumber": "{{random.uuid}}",
  "pressurecontrol": {{random.number(
    {
      "min":5,
      "max":30
    }
  )}},
  "o2stats": {{random.number(
    {
      "min":92,
```

```
        "max":98
    }
  }},
  "minutevolume": {{random.number(
    {
      "min":5,
      "max":8
    }
  )}},
  "manufacturer": "{{random.arrayElement(
    ["3M", "GE","Vyaire", "Getinge"]
  )}}"
}
```

Vous pouvez désormais afficher des données fictives avec Modèle de test et ingérer les données fictives dans Kinesis avec Envoyer des données.


8. Cliquez sur Envoyer des données et générez 5 000 à 10 000 enregistrements vers Kinesis.

Création d'une tâche de AWS Glue streaming avec AWS Glue Studio


AWS Glue Studio est une interface visuelle qui simplifie le processus de conception, d'orchestration et de surveillance des pipelines d'intégration de données. Il permet aux utilisateurs de créer des pipelines de transformation de données sans écrire de code extensif. Outre l'expérience visuelle de création de tâches, AWS Glue Studio inclut également un bloc-notes Jupyter soutenu par des sessions AWS Glue interactives, que vous utiliserez dans le reste de ce didacticiel.

Configuration de la tâche AWS Glue Streaming interactive sessions

1. Téléchargez le [fichier de bloc-notes](#) fourni et enregistrez-le dans un répertoire local.
2. Ouvrez la AWS Glue console et dans le volet de gauche, cliquez sur Carnets de notes > Jupyter Notebook > Télécharger et modifier un bloc-notes existant. Chargez le bloc-notes de l'étape précédente et cliquez sur Créer.



3. Donnez un nom et un rôle à la tâche et sélectionnez le noyau Spark par défaut. Cliquez ensuite sur Démarrer un bloc-notes. Pour le rôle IAM, sélectionnez le rôle fourni par le CloudFormation modèle. Vous pouvez le voir dans l'onglet Sorties de CloudFormation.



Le bloc-notes contient toutes les instructions nécessaires pour poursuivre le didacticiel. Vous pouvez soit exécuter les instructions sur le bloc-notes, soit suivre ce didacticiel pour poursuivre le développement de la tâche.

Exécution des cellules du bloc-notes

1. (Facultatif) La première cellule de code, %help, répertorie toutes les magies de blocs-notes disponibles. Vous pouvez ignorer cette case pour le moment, mais n'hésitez pas à la découvrir.
2. Commencez par le bloc de code suivant %streaming. Cette magie définit le type de tâche en streaming, ce qui vous permet de développer, de déboguer et de déployer une tâche ETL AWS Glue en streaming.
3. Exécutez la cellule suivante pour créer une session AWS Glue interactive. La cellule de sortie contient un message qui confirme la création de la session.

Run this cell to set up and start your interactive session.

```
[1]: %glue_version 3.0

import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue import DynamicFrame
from datetime import datetime
from pyspark.sql.types import StructType, StructField, StringType, LongType
from pyspark.sql.functions import lit,col,from_json
import boto3

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)

Setting Glue version to: 3.0
Authenticating with environment variables and user-defined glue_role_arn: arn:aws:iam::624461700000:role/glue-tutorial-role
Trying to create a Glue session for the kernel.
Worker Type: G.1X
Number of Workers: 5
Session ID: 48af
Job Type: gluestreaming
Applying the following default arguments:
--glue_kernel_version 0.37.3
--enable-glue-datacatalog true
Waiting for session 48af to get into ready status...
Session 48af has been created.
```

4. La cellule suivante définit les variables. Remplacez les valeurs par celles correspondant à votre tâche et exécutez la cellule. Par exemple :

```
output_database_name="default"
output_table_name="test_stream_001"

account_id = boto3.client("sts").get_caller_identity()["Account"]
region_name=boto3.client('s3').meta.region_name
stream_arn_name = "arn:aws:kinesis:{}:{}:stream/GlueStreamTest-{}".format(region_name,account_id,account_id)
s3_bucket_name = "streaming-tutorial-s3-target-{}".format(account_id)

output_location = "s3://{}/streaming_output/{}".format(s3_bucket_name)
checkpoint_location = "s3://{}/checkpoint_location/{}".format(s3_bucket_name)
```

5. Comme les données sont déjà diffusées vers Kinesis Data Streams, votre prochaine cellule utilisera les résultats du flux. Exécutez la cellule suivante. Comme il n'y a aucune instruction print, aucune sortie n'est attendue de cette cellule.
6. Dans la cellule suivante, vous explorez le flux entrant en prenant un ensemble d'échantillons et en imprimant son schéma et les données réelles. Par exemple :

Sample and print the incoming records

the sampling is for debugging purpose. You may comment off the entire code cell below, before deploying the actual code

```
[4]: options = {
    --"pollingTimeInMs": "20000",
    --"windowSize": "5 seconds"
}
sampled_dynamic_frame = glueContext.getSampleStreamingDynamicFrame(data_frame, options, None)

count_of_sampled_records = sampled_dynamic_frame.count()

print(count_of_sampled_records)

sampled_dynamic_frame.printSchema()

sampled_dynamic_frame.toDF().show(10,False)
```

```
100
root
```

```
|-- eventtime: string
|-- manufacturer: string
|-- minutevolume: long
|-- o2stats: long
|-- pressurecontrol: long
|-- serialnumber: string
|-- ventilatorid: long
```

eventtime	manufacturer	minutevolume	o2stats	pressurecontrol	serialnumber	ventilatorid
2023-07-18 10:20:11	3M	6	92	24	a3e860ba-24b9-41c4-bc10-91c6b35e1406	6
2023-07-18 10:20:11	Vyaire	6	95	6	96101dca-3e88-457f-b390-e3291df48a81	26
2023-07-18 10:20:12	Getinge	8	96	24	18f3d448-1dee-4c80-835b-1a0daa818915	22
2023-07-18 10:20:12	Getinge	7	98	30	25f425cd-b978-4953-9a03-4d607a639364	91
2023-07-18 10:20:12	GE	5	93	25	2cd7cdc2-f5f5-4ff2-ae32-45e5a8922d53	93

7. Ensuite, définissez la logique de transformation réelle des données. La cellule comprend la méthode processBatch qui est déclenchée lors de chaque microlot. Exécutez la cellule. À un niveau élevé, nous effectuons les actions suivantes sur le flux entrant :
 - a. Sélectionner un sous-ensemble des colonnes d'entrée.
 - b. Renommer une colonne (o2stats en oxygen_stats).
 - c. Dériver de nouvelles colonnes (serial_identifieur, ingest_year, ingest_month and ingest_day).
 - d. Stockez les résultats dans un compartiment Amazon S3 et créez également une table de AWS Glue catalogue partitionnée
8. Dans la dernière cellule, vous déclenchez le traitement par lots toutes les 10 secondes. Exécutez la cellule et attendez environ 30 secondes pour qu'elle remplisse le compartiment Amazon S3 et la table du AWS Glue catalogue.

9. Enfin, parcourez les données stockées à l’aide de l’éditeur de requêtes Amazon Athena. Vous pouvez voir la colonne renommée ainsi que les nouvelles partitions.

1

select * from test_stream_001 limit 10

SQLLn 1, Col 39

Run again

Explain

Cancel

Clear

Create

Reuse query results

up to 60 minutes ago

Query results

Query stats

Completed

Time in queue: 164 ms

Run time: 1.22 sec

Data scanned: 11.76 KB

Results (10)

Copy

Download results

Search rows

	manufacturer	oxygen_stats	serialnumber	ventilatorid	serial_identifieur	ingest_year	ingest_month	ingest_day
7-18 14:08:12	GE	96	a28895a3-0d57-4d0e-9d5e-86fdc92a5ba8	54	a28895a3	2023	7	18
7-18 14:08:12	Getinge	93	1e7b6e7e-e248-4cc7-971c-7cc7f4bb53e9	94	1e7b6e7e	2023	7	18
7-18 14:08:12	GE	97	52f8b540-4baa-4b90-bc65-986d668e8174	42	52f8b540	2023	7	18
7-18 14:08:12	Vyaire	93	e4ebdf4a-ca96-4465-ba03-681b438d9589	14	e4ebdf4a	2023	7	18
7-18 14:08:12	GE	92	52ba9e2b-748f-4226-9ac0-3767ce900233	33	52ba9e2b	2023	7	18
7-18 14:08:12	Getinge	96	74922910-ddcd-4e03-899b-acdf7487bb6c	8	74922910	2023	7	18

Le bloc-notes contient toutes les instructions nécessaires pour poursuivre le didacticiel. Vous pouvez soit exécuter les instructions sur le bloc-notes, soit suivre ce didacticiel pour poursuivre le développement de la tâche.

Enregistrez et exécutez le AWS Glue travail

Une fois le développement et le test de votre application terminés à l’aide du bloc-notes de sessions interactives, cliquez sur Enregistrer en haut de l’interface du bloc-notes. Une fois enregistrée, vous pouvez également exécuter l’application en tant que tâche.

glue_tutorial_notebook

Stop notebook

Download Notebook

Actions

Save

Run

Notebook

Script

Job details

Runs

Data quality

Schedules

Version Control

Code

Download

Glue PySpark

AWS Glue Streaming Tutorials - Working with Studio Notebook

Nettoyage

Pour éviter d'entraîner des frais supplémentaires sur votre compte, arrêtez la tâche de streaming que vous avez commencée dans le cadre des instructions. Vous pouvez procéder en arrêtant le bloc-notes, ce qui mettra fin à la session. Videz le compartiment Amazon S3 et supprimez la AWS CloudFormation pile que vous avez provisionnée précédemment.

Conclusion

Dans ce didacticiel, nous avons montré comment effectuer les opérations suivantes à l'aide du bloc-notes AWS Glue Studio

- Création d'une tâche ETL en streaming à l'aide de blocs-notes
- Prévisualisation des flux de données entrants
- Codez et corrigez les problèmes sans avoir à publier des AWS Glue offres d'emploi
- Passez en revue le code de end-to-end travail, supprimez tout débogage et imprimez les instructions ou les cellules du bloc-notes
- Publier le code en tant que AWS Glue tâche

L'objectif de ce didacticiel est de vous donner une expérience pratique du AWS Glue streaming et des sessions interactives. Nous vous encourageons à l'utiliser comme référence pour vos cas d'utilisation individuels du AWS Glue streaming. Pour de plus amples informations, veuillez consulter [Démarrage avec AWS Glue sessions interactives](#).

AWS Glue Concepts de diffusion

Les sections suivantes fournissent des informations sur les concepts du AWS Glue streaming.

Rubriques

- [Anatomie d'une tâche AWS Glue de streaming](#)

Anatomie d'une tâche AWS Glue de streaming

AWS Glue les jobs de streaming fonctionnent selon le paradigme de streaming Spark et tirent parti du streaming structuré à partir du framework Spark. Les tâches de streaming interrogent en permanence la source de données de streaming, à un intervalle de temps spécifique, pour récupérer

les enregistrements sous forme de microlots. Les sections suivantes examinent les différentes parties d'une tâche de AWS Glue streaming.

```
def processBatch(data_frame, batchId):
    2
    if data_frame.count() > 0:
        3
        AmazonKinesis_node1696872487972 = DynamicFrame.fromDF(
            glueContext.add_ingestion_time_columns(data_frame, "hour"),
            glueContext,
            "from_data_frame",
        )
        # Script generated for node Change Schema
        4
        ChangeSchema_node1696872679326 = ApplyMapping.apply(
            frame=AmazonKinesis_node1696872487972,
            mappings=[
                ("eventtime", "string", "eventtime", "string"),
                ("manufacturer", "string", "manufacturer", "string"),
                ("minutevolume", "long", "minutevolume", "int"),
                ("o2stats", "long", "OxygenSaturation", "int"),
                ("pressurecontrol", "long", "pressurecontrol", "int"),
                ("serialnumber", "string", "serialnumber", "string"),
                ("ventilatorid", "long", "ventilatorid", "long"),
                ("ingest_year", "string", "ingest_year", "string"),
                ("ingest_month", "string", "ingest_month", "string"),
                ("ingest_day", "string", "ingest_day", "string"),
                ("ingest_hour", "string", "ingest_hour", "string"),
            ],
            transformation_ctx="ChangeSchema_node1696872679326",
        )
        # Script generated for node Amazon S3
        AmazonS3_node1696872743449_path = (
            "s3://streaming-tutorial-s3-target-"
        )
        5
        AmazonS3_node1696872743449 = glueContext.getSink(
            path=AmazonS3_node1696872743449_path,
            connection_type="s3",
            updateBehavior="UPDATE_IN_DATABASE",
            partitionKeys=["ingest_year", "ingest_month", "ingest_day", "ingest_hour"],
            compression="snappy",
            enableUpdateCatalog=True,
            transformation_ctx="AmazonS3_node1696872743449",
        )
        6
        AmazonS3_node1696872743449.setCatalogInfo(
            catalogDatabase="demo", catalogTableName="demo_stream_transform_result"
        )
        AmazonS3_node1696872743449.setFormat("glueparquet")
        AmazonS3_node1696872743449.writeFrame(ChangeSchema_node1696872679326)
        1 ← Entry Point
    glueContext.forEachBatch(
        frame=dataFrame_AmazonKinesis_node1696872487972,
        batch_function=processBatch,
        options={
            "windowSize": "100 seconds",
            "checkpointLocation": args["TempDir"] + "/" + args["JOB_NAME"] + "/"
        },
    ),
    job.commit()
```

forEachBatch

La `forEachBatch` méthode est le point d'entrée d'une tâche de AWS Glue streaming exécutée. AWS Glue les tâches de streaming utilisent la `forEachBatch` méthode d'interrogation des données qui fonctionne comme un itérateur qui reste actif pendant le cycle de vie de la tâche de streaming, interroge régulièrement la source de streaming à la recherche de nouvelles données et traite les données les plus récentes par microlots.

```
glueContext.forEachBatch(
    frame=dataFrame_AmazonKinesis_node1696872487972,
    batch_function=processBatch,
    options={
        "windowSize": "100 seconds",
        "checkpointLocation": args["TempDir"] + "/" + args["JOB_NAME"] + "/"
    },
)
```


Configurez la propriété `frame` de `forEachBatch` pour spécifier une source de streaming. Dans cet exemple, le nœud source que vous avez créé dans le canevas vierge lors de la création de la tâche est renseigné avec la valeur par défaut `DataFrame` de la tâche. Définissez la propriété `batch_function` comme la fonction que vous décidez d'invoquer pour chaque opération de microlot. Vous devez définir une fonction pour gérer la transformation par lots des données entrantes.

Source

Dans la première étape de la `processBatch` fonction, le programme vérifie le nombre d'enregistrements de `DataFrame` ce que vous avez défini comme propriété de cadre `deforEachBatch`. Le programme ajoute un horodatage d'ingestion à un fichier non `DataFrame` vide. La clause `data_frame.count() > 0` détermine si le dernier microlot n'est pas vide et est prêt pour un traitement ultérieur.

```
def processBatch(data_frame, batchId):
    if data_frame.count() > 0:
        AmazonKinesis_node1696872487972 = DynamicFrame.fromDF(
            glueContext.add_ingestion_time_columns(data_frame, "hour"),
            glueContext,
            "from_data_frame",
        )
```

Mappage

La section suivante du programme consiste à appliquer le mappage. La `Mapping.apply` méthode sur une étincelle vous `DataFrame` permet de définir une règle de transformation autour des éléments de données. Vous pouvez généralement renommer, modifier le type de données ou appliquer une fonction personnalisée à la colonne de données source et les faire correspondre aux colonnes cibles.

```
#Script generated for node ChangeSchema
ChangeSchema_node16986872679326 = ApplyMapping.apply(
    frame = AmazonKinesis_node1696872487972,
    mappings = [
        ("eventtime", "string", "eventtime", "string"),
        ("manufacturer", "string", "manufacturer", "string"),
        ("minutevolume", "long", "minutevolume", "int"),
```

```

        ("o2stats", "long", "OxygenSaturation", "int"),
        ("pressurecontrol", "long", "pressurecontrol", "int"),
        ("serialnumber", "string", "serialnumber", "string"),
        ("ventilatorid", "long", "ventilatorid", "long"),
        ("ingest_year", "string", "ingest_year", "string"),
        ("ingest_month", "string", "ingest_month", "string"),
        ("ingest_day", "string", "ingest_day", "string"),
        ("ingest_hour", "string", "ingest_hour", "string"),
    ],
    transformation_ctx="ChangeSchema_node16986872679326",
)
)

```

Sink

Dans cette section, le jeu de données entrant provenant de la source de streaming est stocké dans un emplacement cible. Dans cet exemple, nous écrivons les données dans un emplacement Amazon S3. Les détails de la propriété `AmazonS3_node_path` sont préremplis en fonction des paramètres que vous avez utilisés lors de la création de tâches à partir du canevas. Vous pouvez définir le `updateBehavior` en fonction de votre cas d'utilisation et décider soit de ne pas mettre à jour la table du catalogue de données, soit de créer le catalogue de données et de mettre à jour le schéma du catalogue de données lors des exécutions suivantes, soit de créer une table de catalogue sans mettre à jour la définition du schéma lors des exécutions suivantes.

La propriété `partitionKeys` définit l'option de partition de stockage. Le comportement par défaut consiste à partitionner les données conformément aux `ingestion_time_columns` mises à disposition dans la section source. La propriété `compression` vous permet de définir l'algorithme de compression à appliquer lors de l'écriture cible. Vous avez la possibilité de définir Snappy, LZO ou GZIP comme technique de compression. La propriété `enableUpdateCatalog` détermine si la table du catalogue AWS Glue doit être mise à jour. Les options disponibles pour cette propriété sont `True` ou `False`.

```

#Script generated for node Amazon S3
AmazonS3_node1696872743449 = glueContext.getSink(
    path = AmazonS3_node1696872743449_path,
    connection_type = "s3",
    updateBehavior = "UPDATE_IN_DATABASE",
    partitionKeys = ["ingest_year", "ingest_month", "ingest_day", "ingest_hour"],
    compression = "snappy",

```

```
enableUpdateCatalog = True,  
transformation_ctx = "AmazonS3_node1696872743449",  
)
```

AWS Glue évier de catalogue

Cette section de la tâche contrôle le comportement de mise à jour des tables de AWS Glue catalogue. Définissez `catalogDatabase` et `catalogTableName` propriétés selon le nom de votre base de données AWS Glue Catalog et le nom de table associé à la AWS Glue tâche que vous concevez. Vous pouvez définir le format de fichier des données cibles via la propriété `setFormat`. Dans cet exemple, nous allons stocker les données au format parquet.

Une fois que vous avez configuré et exécuté la tâche de AWS Glue streaming en vous référant à ce didacticiel, les données de streaming produites sur le site Amazon S3 Amazon Kinesis Data Streams seront stockées sur le site Amazon S3 dans un format parquet avec une compression rapide. En cas d'exécution réussie de la tâche de streaming, vous pourrez interroger les données via Amazon Athena.

```
AmazonS3_node1696872743449 = setCatalogInfo(  
    catalogDatabase = "demo", catalogTableName = "demo_stream_transform_result"  
)  
AmazonS3_node1696872743449.setFormat("glueparquet")  
AmazonS3_node1696872743449.writeFormat("ChangeSchema_node16986872679326")  
)
```

AWS Glue Connexions de streaming

Les sections suivantes fournissent des informations sur l'utilisation des connexions dans AWS Glue Streaming.

Rubriques

- [Utilisation des connexions Kafka](#)
- [Utilisation des connexions Kinesis](#)

Utilisation des connexions Kafka

Vous pouvez utiliser une connexion Kafka pour lire et écrire dans des flux de données Kafka à l'aide des informations stockées dans une table du catalogue de données, ou en fournissant des informations pour accéder directement au flux de données. La connexion prend en charge un cluster Kafka ou un cluster Amazon Managed Streaming for Apache Kafka. Vous pouvez lire les informations de Kafka dans un Spark DataFrame, puis les convertir en AWS Glue DynamicFrame. Vous pouvez DynamicFrames écrire dans Kafka au format JSON. Si vous accédez directement au flux de données, utilisez ces options pour fournir des informations sur la façon d'accéder au flux de données.

Si vous utilisez `getCatalogSource` ou `create_data_frame_from_catalog` pour consommer des enregistrements provenant d'une source de streaming Kafka, `getCatalogSink` ou `write_dynamic_frame_from_catalog` pour écrire des enregistrements sur Kafka, et que la tâche contient les informations de base de données et de nom de table du catalogue de données, et que vous pouvez les utiliser pour obtenir certains paramètres de base pour la lecture à partir de la source de streaming Kafka. Si vous utilisez `getSource`, `getCatalogSink`, `getSourceWithFormat`, `createDataFrameFromOptions` ou `getSinkWithFormat`, ou `create_data_frame_from_options`, `write_dynamic_frame_from_catalog`, vous devez spécifier ces paramètres de base à l'aide des options de connexion décrites ici.

Vous pouvez spécifier les options de connexion pour Kafka à l'aide des arguments suivants pour les méthodes spécifiées dans la `GlueContext` classe.

- Scala
 - `connectionOptions` : utiliser avec `getSource`, `createDataFrameFromOptions`, `getSink`
 - `additionalOptions` : utiliser avec `getCatalogSource`, `getCatalogSink`
 - `options` : utiliser avec `getSourceWithFormat`, `getSinkWithFormat`
- Python
 - `connection_options` : utiliser avec `create_data_frame_from_options`, `write_dynamic_frame_from_options`
 - `additional_options` : utiliser avec `create_data_frame_from_catalog`, `write_dynamic_frame_from_catalog`
 - `options` : utiliser avec `getSource`, `getSink`

Pour les remarques et les restrictions concernant les tâches ETL de streaming, consultez [the section called “Restrictions et notes sur ETL en streaming”](#).

Configurer Kafka

Il n'y a aucune AWS condition préalable pour se connecter aux flux Kafka disponibles sur Internet.

Vous pouvez créer une connexion AWS Glue Kafka pour gérer vos identifiants de connexion. Pour de plus amples informations, veuillez consulter [the section called “Création d'une connexion pour un flux de données Kafka”](#). Dans la configuration de votre tâche AWS Glue, fournissez *connectionName* une connexion réseau supplémentaire, puis, dans votre appel de méthode, fournissez *connectionName* le *connectionName* paramètre.

Dans certains cas, vous devrez configurer des prérequis supplémentaires :

- Si vous utilisez Amazon Managed Streaming pour Apache Kafka avec l'authentification IAM, vous aurez besoin d'une configuration IAM appropriée.
- Si vous utilisez Amazon Managed Streaming pour Apache Kafka avec un Amazon VPC, vous aurez besoin d'une configuration Amazon VPC appropriée. Vous devez créer une connexion AWS Glue fournissant les informations de connexion Amazon VPC. Vous aurez besoin de la configuration de votre tâche pour inclure la connexion AWS Glue en tant que connexion réseau supplémentaire.

Pour plus d'informations sur les prérequis de la tâche ETL de streaming, consultez [the section called “Tâches ETL en streaming”](#).

Exemple : lecture à partir de flux Kafka

Utilisez conjointement avec [the section called “forEachBatch”](#).

Exemple pour la source de streaming Kafka :

```
kafka_options =  
  { "connectionName": "ConfluentKafka",  
    "topicName": "kafka-auth-topic",  
    "startingOffsets": "earliest",  
    "inferSchema": "true",  
    "classification": "json"  
  }
```

```
data_frame_datasource0 =  
    glueContext.create_data_frame.from_options(connection_type="kafka",  
        connection_options=kafka_options)
```

Exemple : écrire dans des flux Kafka

Exemples pour écrire à Kafka :

Exemple avec la `getSink` méthode :

```
data_frame_datasource0 =  
glueContext.getSink(  
    connectionType="kafka",  
    connectionOptions={  
        JsonOptions("""{  
            "connectionName": "ConfluentKafka",  
            "classification": "json",  
            "topic": "kafka-auth-topic",  
            "typeOfData": "kafka"}  
        """))},  
    transformationContext="dataframe_ApacheKafka_node1711729173428")  
.getDataFrame()
```

Exemple avec la `write_dynamic_frame.from_options` méthode :

```
kafka_options =  
    { "connectionName": "ConfluentKafka",  
      "topicName": "kafka-auth-topic",  
      "classification": "json"  
    }  
data_frame_datasource0 =  
    glueContext.write_dynamic_frame.from_options(connection_type="kafka",  
        connection_options=kafka_options)
```

Référence des options de connexion de Kafka

Lorsque vous lisez, utilisez les options de connexion suivantes avec `"connectionType"` : `"kafka"` :

- `"bootstrap.servers"` (Obligatoire) Une liste de serveurs bootstrap URLs, par exemple, `comneb-1.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094`. Cette

option doit être spécifiée dans l'appel d'API ou définie dans les métadonnées de la table dans le catalogue de données.

- `"security.protocol"` (Obligatoire) Le protocole utilisé pour communiquer avec les agents. Les valeurs possibles sont `"SSL"` ou `"PLAINTEXT"`.
- `"topicName"` : (requis) liste de rubriques séparées par des virgules auxquelles s'abonner. Vous devez spécifier un seul et unique élément parmi `"topicName"`, `"assign"` ou `"subscribePattern"`.
- `"assign"` : (requis) chaîne JSON indiquant le `TopicPartitions` spécifique à utiliser. Vous devez spécifier un seul et unique élément parmi `"topicName"`, `"assign"` ou `"subscribePattern"`.

Exemple : `'{"topicA":[0,1],"topicB":[2,4]}'`

- `"subscribePattern"` : (obligatoire) chaîne d'expression rationnelle Java qui identifie la liste de rubriques à laquelle vous souhaitez vous abonner. Vous devez spécifier un seul et unique élément parmi `"topicName"`, `"assign"` ou `"subscribePattern"`.

Exemple : `'topic.*'`

- `"classification"` : (obligatoire) le format de fichier utilisé par les données de l'enregistrement. Obligatoire, sauf s'il est fourni par le catalogue de données.
- `"delimiter"` : (facultatif) le séparateur de valeurs utilisé lorsque `classification` est CSV. La valeur par défaut est « , ».
- `"startingOffsets"` : (facultatif) position de départ dans la rubrique Kafka à partir de laquelle lire les données. Les valeurs possibles sont `"earliest"` ou `"latest"`. La valeur par défaut est `"latest"`.
- `"startingTimestamp"`: (Facultatif, disponible uniquement pour AWS la version 4.0 ou ultérieure de Glue) Horodatage de l'enregistrement dans la rubrique Kafka à partir duquel les données doivent être lues. La valeur possible est une chaîne d'horodatage au format UTC dans le modèle `yyyy-mm-ddTHH:MM:SSZ` (où Z représente un décalage de fuseau horaire UTC avec un +/-). Par exemple : « `2023-04-04T08:00:00-04:00` »).

Remarque : seule l'une des propriétés « `StartingOffsets` » ou « `StartingTimestamp` » peut figurer dans la liste des options de connexion du script de streaming AWS Glue. L'inclusion de ces deux propriétés entraînera l'échec de la tâche.

- "endingOffsets" : (facultatif) point de fin lorsqu'une requête par lots est terminée. Les valeurs possibles sont "latest" ou une chaîne JSON qui spécifie un décalage de fin pour chaque TopicPartition.

Pour la chaîne JSON, le format est {"topicA":{"0":23,"1":-1},"topicB":{"0":-1}}. La valeur -1 en tant que décalage représente "latest".

- "pollTimeoutMs" : (facultatif) délai d'attente en millisecondes pour interroger les données de Kafka dans les exécuteurs de tâches Spark. La valeur par défaut est 600000.
- "numRetries" : (facultatif) nombre de nouvelles tentatives avant de ne pas récupérer les décalages Kafka. La valeur par défaut est 3.
- "retryIntervalMs" : (facultatif) temps d'attente en millisecondes avant d'essayer de récupérer les décalages Kafka. La valeur par défaut est 10.
- "maxOffsetsPerTrigger" : (facultatif) limite de taux sur le nombre maximal de décalages qui sont traités par intervalle de déclenchement. Le nombre total spécifié de décalages est réparti proportionnellement entre les topicPartitions des différents volumes. La valeur par défaut est null, ce qui signifie que le consommateur lit tous les décalages jusqu'au dernier décalage connu.
- "minPartitions" : (facultatif) nombre minimum de partitions à lire à partir de Kafka. La valeur par défaut est nulle, ce qui signifie que le nombre de partitions Spark est égal au nombre de partitions Kafka.
- "includeHeaders" : (facultatif) indique s'il faut inclure les en-têtes Kafka. Lorsque l'option est définie sur « true » (vrai), la sortie de données contiendra une colonne supplémentaire nommée « glue_streaming_kafka_headers » avec le type Array[Struct(key: String, value: String)]. La valeur définie par défaut est « false ». Cette option est disponible dans AWS Glue version 3.0 ou ultérieure.
- "schema" : (requis lorsque inferSchema est défini sur false) schéma à utiliser pour traiter la charge utile. Si la classification est avro, le schéma fourni doit être au format de schéma Avro. Si la classification n'est pas avro, le schéma fourni doit être au format de schéma DDL.

Voici quelques exemples de schémas.

Exemple in DDL schema format

```
'column1' INT, 'column2' STRING , 'column3' FLOAT
```

Exemple in Avro schema format

```
{
```



```

"type": "array",
"items":
{
  "type": "record",
  "name": "test",
  "fields":
  [
    {
      "name": "_id",
      "type": "string"
    },
    {
      "name": "index",
      "type":
      [
        "int",
        "string",
        "float"
      ]
    }
  ]
}
]
}
}

```

- **"inferSchema"** : (facultatif) la valeur par défaut est « false ». S'il est défini sur « true », le schéma sera détecté lors de l'exécution à partir de la charge utile dans `foreachbatch`.
- **"avroSchema"** : (obsolète) paramètre utilisé pour spécifier un schéma de données Avro lorsque le format Avro est utilisé. Ce paramètre est désormais obsolète. Utilisez le paramètre `schema`.
- **"addRecordTimestamp"** : (facultatif) lorsque cette option est définie sur « true », la sortie de données contient une colonne supplémentaire nommée « `__src_timestamp` » qui indique l'heure à laquelle l'enregistrement correspondant est reçu par la rubrique. La valeur par défaut est « false ». Cette option est prise en charge dans AWS Glue version 4.0 ou ultérieure.
- **"emitConsumerLagMetrics"** : (Facultatif) Lorsque l'option est définie sur « vrai », pour chaque lot, elle émet les métriques correspondant à la durée comprise entre le plus ancien enregistrement reçu par le sujet et le moment où il arrive AWS Glue à CloudWatch. Le nom de la métrique est « `glue.driver.streaming` ». `maxConsumerLagInMs` ». La valeur par défaut est « false ». Cette option est prise en charge dans AWS Glue version 4.0 ou ultérieure.

Lorsque vous écrivez, utilisez les options de connexion suivantes avec **"connectionType"** :
"kafka" :

- "connectionName"(Obligatoire) Nom de la connexion AWS Glue utilisée pour se connecter au cluster Kafka (similaire à la source Kafka).
- "topic"(Obligatoire) Si une colonne de sujet existe, sa valeur est utilisée comme sujet lors de l'écriture de la ligne donnée dans Kafka, sauf si l'option de configuration du sujet est définie. C'est-à-dire que l'option topic de configuration remplace la colonne du sujet.
- "partition"(Facultatif) Si un numéro de partition valide est spécifié, il partition sera utilisé lors de l'envoi de l'enregistrement.

Si aucune partition n'est spécifiée mais key que a est présent, une partition sera choisie en utilisant le hachage de la clé.

Si ni l'un key ni l'autre n'partitionest présent, une partition sera choisie en partitionnant de manière permanente ces modifications lorsqu'au moins des octets batch.size seront produits sur la partition.

- "key"(Facultatif) Utilisé pour le partitionnement s'il partition est nul.
- "classification"(Facultatif) Format de fichier utilisé par les données de l'enregistrement. Nous prenons uniquement en charge les formats JSON, CSV et Avro.

Avec le format Avro, nous pouvons fournir un AvroSchema personnalisé avec lequel sérialiser, mais notez que cela doit également être fourni sur la source pour la désérialisation. Sinon, par défaut, il utilise Apache AvroSchema pour la sérialisation.

En outre, vous pouvez ajuster le récepteur Kafka selon les besoins en mettant à jour les paramètres de configuration du [producteur Kafka](#). Notez qu'il n'existe aucune liste d'autorisation pour les options de connexion, toutes les paires clé-valeur sont conservées telles quelles sur le récepteur.

Cependant, il existe une petite liste d'options refusées qui ne prendront pas effet. Pour plus d'informations, consultez la section [Configurations spécifiques à Kafka](#).

Utilisation des connexions Kinesis

Vous pouvez utiliser une connexion Kinesis pour lire et écrire dans les flux de données Amazon Kinesis à l'aide des informations stockées dans une table du catalogue de données ou en fournissant des informations pour accéder directement au flux de données. Vous pouvez lire les informations de Kinesis dans un Spark DataFrame, puis les convertir en Glue AWS . DynamicFrame Vous pouvez DynamicFrames écrire dans Kinesis au format JSON. Si vous accédez directement au flux de données, utilisez ces options pour fournir des informations sur la façon d'accéder au flux de données.

Si vous utilisez `getCatalogSource` ou `create_data_frame_from_catalog` pour consommer des enregistrements à partir d'une source de streaming Kinesis, la tâche dispose des informations relatives à la base de données Data Catalog et au nom de la table, et peut les utiliser pour obtenir certains paramètres de base pour la lecture à partir de la source de streaming Kinesis.

Si vous utilisez `getSource`, `getSourceWithFormat`, `createDataFrameFromOptions` ou `create_data_frame_from_options`, vous devez spécifier ces paramètres de base à l'aide des options de connexion décrites ici.

Vous pouvez spécifier les options de connexion pour Kinesis à l'aide des arguments suivants pour les méthodes spécifiées dans la classe `GlueContext`.

- Scala
 - `connectionOptions` : utiliser avec `getSource`, `createDataFrameFromOptions`, `getSink`
 - `additionalOptions` : utiliser avec `getCatalogSource`, `getCatalogSink`
 - `options` : utiliser avec `getSourceWithFormat`, `getSinkWithFormat`
- Python
 - `connection_options` : utiliser avec `create_data_frame_from_options`, `write_dynamic_frame_from_options`
 - `additional_options` : utiliser avec `create_data_frame_from_catalog`, `write_dynamic_frame_from_catalog`
 - `options` : utiliser avec `getSource`, `getSink`

Pour les remarques et les restrictions concernant les tâches ETL de streaming, consultez [the section called “Restrictions et notes sur ETL en streaming”](#).

Configurer Kinesis

Pour vous connecter à un flux de données Kinesis dans le cadre d'une tâche AWS Glue Spark, vous aurez besoin de certaines conditions préalables :

- En cas de lecture, la tâche AWS Glue doit disposer d'autorisations IAM de niveau d'accès en lecture pour le flux de données Kinesis.
- En cas d'écriture, la tâche AWS Glue doit disposer d'autorisations IAM de niveau d'accès Write au flux de données Kinesis.

Dans certains cas, vous devrez configurer des prérequis supplémentaires :

- Si votre tâche AWS Glue est configurée avec des connexions réseau supplémentaires (généralement pour se connecter à d'autres ensembles de données) et que l'une de ces connexions fournit des options de réseau Amazon VPC, cela indiquera à votre tâche de communiquer via Amazon VPC. Dans ce cas, vous devrez également configurer votre flux de données Kinesis pour qu'il communique via Amazon VPC. Vous pouvez le faire en créant un point de terminaison d'un VPC d'interface entre votre Amazon VPC et votre flux de données Kinesis. Pour plus d'informations, consultez [Using Kinesis Data Streams with Interface VPC Endpoints](#).
- Lorsque vous spécifiez Amazon Kinesis Data Streams dans un autre compte, vous devez configurer les rôles et les stratégies pour autoriser l'accès intercompte. Pour de plus amples informations, veuillez consulter la rubrique [Exemple : Lire à partir d'un flux Kinesis dans un autre compte](#).

Pour plus d'informations sur les prérequis de la tâche ETL de streaming, consultez [the section called "Tâches ETL en streaming"](#).

Lecture depuis Kinesis

Exemple : lecture à partir de flux Kinesis

Utilisez conjointement avec [the section called "forEachBatch"](#).

Exemple pour la source de streaming Amazon Kinesis :

```
kinesis_options =  
  { "streamARN": "arn:aws:kinesis:us-east-2:777788889999:stream/fromOptionsStream",  
    "startingPosition": "TRIM_HORIZON",  
    "inferSchema": "true",  
    "classification": "json"  
  }  
data_frame_datasource0 =  
  glueContext.create_data_frame.from_options(connection_type="kinesis",  
    connection_options=kinesis_options)
```

Écrire à Kinesis

Exemple : écriture dans Kinesis Streams

Utilisez conjointement avec [the section called "forEachBatch"](#). Vous DynamicFrame serez écrit dans le flux au format JSON. Si la tâche ne parvient pas à écrire après plusieurs tentatives, elle échoue.

Par défaut, chaque `DynamicFrame` enregistrement est envoyé au flux Kinesis individuellement. Vous pouvez configurer ce comportement à l'aide de la commande `aggregationEnabled` et des paramètres associés.

Exemple d'écriture sur Amazon Kinesis à partir d'une tâche de diffusion :

Python

```
glueContext.write_dynamic_frame.from_options(  
    frame=frameToWrite  
    connection_type="kinesis",  
    connection_options={  
        "partitionKey": "part1",  
        "streamARN": "arn:aws:kinesis:us-east-1:111122223333:stream/streamName",  
    }  
)
```

Scala

```
glueContext.getSinkWithFormat(  
    connectionType="kinesis",  
    options=JsonOptions("""{  
        "streamARN": "arn:aws:kinesis:us-  
east-1:111122223333:stream/streamName",  
        "partitionKey": "part1"  
    }"""),  
)  
    .writeDynamicFrame(frameToWrite)
```

Paramètres de connexion Kinesis

Désigne des options de connexion à Amazon Kinesis Data Streams.

Utilisez les options de connexion suivantes pour les sources de données en streaming Kinesis :

- "streamARN" (Obligatoire) Utilisé pour la lecture/l'écriture. ARN du flux de données Kinesis.
- "classification" (Obligatoire pour la lecture) Utilisé pour la lecture. Format de fichier utilisé par les données de l'enregistrement. Obligatoire, sauf s'il est fourni par le catalogue de données.
- "streamName" : (facultatif) utilisé pour la lecture. Nom du flux de données Kinesis à partir duquel lire. Utilisé avec `endpointUrl`.

- "endpointUrl" : (facultatif) utilisé pour la lecture. Par défaut : « https://kinesis.us-east-1.amazonaws.com ». AWS Point de terminaison du flux Kinesis. Vous n'avez pas besoin de modifier ce paramètre, sauf si vous vous connectez à une région spéciale.
- "partitionKey" : (facultatif) utilisé pour l'écriture. Clé de partition Kinesis utilisée lors de la production d'enregistrements.
- "delimiter" : (facultatif) utilisé pour la lecture. Séparateur de valeurs utilisé lorsque classification est CSV. La valeur par défaut est « , ».
- "startingPosition" : (facultatif) utilisé pour la lecture. La position de départ dans le flux de données Kinesis à partir duquel lire les données. Les valeurs possibles sont "latest", "trim_horizon", "earliest", ou une chaîne d'horodatage au format UTC dans le modèle yyyy-mm-ddTHH:MM:SSZ (où Z représente un décalage de fuseau horaire UTC avec un +/-). Par exemple : « 2023-04-04T08:00:00-04:00 ». La valeur par défaut est "latest". Remarque : la chaîne d'horodatage au format UTC pour n'"startingPosition"est prise en charge que pour la version 4.0 ou ultérieure de AWS Glue.
- "failOnDataLoss" : (facultatif) échec de la tâche si une partition active est manquante ou a expiré. La valeur par défaut est "false".
- "awsSTSRoleARN" : (facultatif) utilisé pour la lecture/l'écriture. Le nom de ressource Amazon (ARN) du rôle à assumer en utilisant AWS Security Token Service (AWS STS). Ce rôle doit disposer des autorisations nécessaires pour écrire ou lire des registres pour le flux de données Kinesis. Vous devez utiliser ce paramètre lorsque vous accédez à un flux de données dans un autre compte. Utilisez conjointement avec "awsSTSSessionName".
- "awsSTSSessionName" : (facultatif) utilisé pour la lecture/l'écriture. Un identifiant de la séance assumant le rôle à l'aide d' AWS STS. Vous devez utiliser ce paramètre lorsque vous accédez à un flux de données dans un autre compte. Utilisez conjointement avec "awsSTSRoleARN".
- "awsSTSEndpoint" : (Facultatif) Le AWS STS point de terminaison à utiliser lors de la connexion à Kinesis avec un rôle assumé. Cela permet d'utiliser le point de AWS STS terminaison régional dans un VPC, ce qui n'est pas possible avec le point de terminaison global par défaut.
- "maxFetchTimeInMs" : (facultatif) utilisé pour la lecture. Durée maximale pendant laquelle l'exécuteur de tâches lit les enregistrements du lot en cours à partir du flux de données Kinesis, spécifiée en millisecondes (ms). Plusieurs appels GetRecords d'API peuvent être effectués pendant cette période. La valeur par défaut est 1000.
- "maxFetchRecordsPerShard" : (facultatif) utilisé pour la lecture. Nombre maximal d'enregistrements à récupérer par partition dans le flux de données Kinesis par microbatch. Remarque : le client peut dépasser cette limite si la tâche de streaming a déjà lu des

enregistrements supplémentaires provenant de Kinesis (lors du même appel `get-records`). Si elle `maxFetchRecordsPerShard` doit être stricte, elle doit être un multiple de `maxRecordPerRead`. La valeur par défaut est `100000`.

- `"maxRecordPerRead"` : (facultatif) utilisé pour la lecture. Nombre maximal d'enregistrements à extraire du flux de données Kinesis dans chaque opération `getRecords`. La valeur par défaut est `10000`.
- `"addIdleTimeBetweenReads"` : (facultatif) utilisé pour la lecture. Ajoute un délai entre deux opérations `getRecords` consécutives. La valeur par défaut est `"False"`. Cette option n'est configurable que pour Glue version 2.0 et ultérieure.
- `"idleTimeBetweenReadsInMs"` : (facultatif) utilisé pour la lecture. Délai minimum entre deux opérations `getRecords`, en ms. La valeur par défaut est `1000`. Cette option n'est configurable que pour Glue version 2.0 et ultérieure.
- `"describeShardInterval"` : (facultatif) utilisé pour la lecture. Intervalle de temps minimum entre deux appels d'API `ListShards` pour que votre script envisage le repartitionnement. Pour plus d'informations, consultez [Politiques de repartitionnement](#) dans le Guide du développeur Amazon Kinesis Data Streams. La valeur par défaut est `1s`.
- `"numRetries"` : (facultatif) utilisé pour la lecture. Le nombre maximal de nouvelles tentatives pour les demandes d'API Kinesis Data Streams. La valeur par défaut est `3`.
- `"retryIntervalMs"` : (facultatif) utilisé pour la lecture. Le délai de réflexion (spécifié en ms) avant de réessayer l'appel d'API Kinesis Data Streams. La valeur par défaut est `1000`.
- `"maxRetryIntervalMs"` : (facultatif) utilisé pour la lecture. Le délai d'attente maximal (spécifié en ms) entre deux tentatives d'appel d'API Kinesis Data Streams. La valeur par défaut est `10000`.
- `"avoidEmptyBatches"` : (facultatif) utilisé pour la lecture. Évite de créer une tâche de micro-lot vide en vérifiant les données non lues dans le flux de données Kinesis avant le démarrage du lot. La valeur par défaut est `"False"`.
- `"schema"` : (obligatoire lorsque `inferSchema` est défini sur `false`) utilisé pour la lecture. Schéma à utiliser pour traiter la charge utile. Si la classification est `avro`, le schéma fourni doit être au format de schéma Avro. Si la classification n'est pas `avro`, le schéma fourni doit être au format de schéma DDL.

Voici quelques exemples de schémas.

Exemple in DDL schema format

```
`column1` INT, `column2` STRING , `column3` FLOAT
```

Example in Avro schema format

```
{
  "type": "array",
  "items": {
    "type": "record",
    "name": "test",
    "fields": [
      {
        "name": "_id",
        "type": "string"
      },
      {
        "name": "index",
        "type": [
          "int",
          "string",
          "float"
        ]
      }
    ]
  }
}
```

- "inferSchema" : (facultatif) utilisé pour la lecture. La valeur par défaut est « false ». S'il est défini sur « true », le schéma sera détecté lors de l'exécution à partir de la charge utile dans foreachbatch.
- "avroSchema" : (obsolète) utilisé pour la lecture. Paramètre utilisé pour spécifier un schéma de données Avro lorsque le format Avro est utilisé. Ce paramètre est désormais obsolète. Utilisez le paramètre schema.
- "addRecordTimestamp" : (facultatif) utilisé pour la lecture. Lorsque cette option est définie sur « true », la sortie de données contient une colonne supplémentaire nommée « __src_timestamp » qui indique l'heure à laquelle l'enregistrement correspondant est reçu par le flux. La valeur par défaut est « false ». Cette option est prise en charge dans AWS Glue version 4.0 ou ultérieure.
- "emitConsumerLagMetrics" : (facultatif) utilisé pour la lecture. Lorsque l'option est définie sur « vrai », pour chaque lot, elle émet les métriques correspondant à la durée comprise entre le plus ancien enregistrement reçu par le flux et l'heure à laquelle il arrive AWS Glue à CloudWatch. Le

nom de la métrique est « glue.driver.streaming ». maxConsumerLagInMs». La valeur par défaut est « false ». Cette option est prise en charge dans AWS Glue version 4.0 ou ultérieure.

- "fanoutConsumerARN" : (facultatif) utilisé pour la lecture. ARN d'un consommateur de flux Kinesis pour le flux spécifié dans streamARN. Utilisé pour activer le mode diffusion améliorée pour votre connexion Kinesis. Pour plus d'informations sur la consommation d'un flux Kinesis avec diffusion améliorée, consultez [the section called "Utilisation de la diffusion améliorée dans les tâches de streaming Kinesis"](#).
- "recordMaxBufferedTime" : (facultatif) utilisé pour l'écriture. Par défaut : 1 000 (ms). Durée maximale pendant laquelle un enregistrement est mis en mémoire tampon en attendant d'être écrit.
- "aggregationEnabled" : (facultatif) utilisé pour l'écriture. Valeur par défaut : vraie. Spécifie si les enregistrements doivent être agrégés avant de les envoyer à Kinesis.
- "aggregationMaxSize" : (facultatif) utilisé pour l'écriture. Par défaut : 51 200 (octets). Si un enregistrement est supérieur à cette limite, il contourne l'agrégateur. Remarque Kinesis impose une limite de 50 Ko à la taille des enregistrements. Si vous définissez ce paramètre au-delà de 50 Ko, les enregistrements surdimensionnés seront rejetés par Kinesis.
- "aggregationMaxCount" : (facultatif) utilisé pour l'écriture. Par défaut : 4294967295. Nombre maximum de résultats à regrouper dans un enregistrement agrégé.
- "producerRateLimit" : (facultatif) utilisé pour l'écriture. Par défaut : 150 (%). Limite le débit par partition envoyée par un seul producteur (votre tâche, par exemple), sous forme de pourcentage de la limite du backend.
- "collectionMaxCount" : (facultatif) utilisé pour l'écriture. Par défaut : 500. Nombre maximum d'articles à inclure dans une PutRecords demande.
- "collectionMaxSize" : (facultatif) utilisé pour l'écriture. Par défaut : 5242880 (octets). Quantité maximale de données à envoyer avec une PutRecords demande.

AWS Glue mise à l'échelle automatique du streaming

AWS Glue les tâches ETL de streaming consomment en permanence des données provenant de sources de streaming, nettoient et transforment les données en cours de vol, et les mettent à disposition pour analyse. En surveillant chaque étape de l'exécution de la tâche, AWS Glue l'autoscaling peut désactiver les travailleurs lorsqu'ils sont inactifs ou en ajouter si un traitement parallèle supplémentaire est possible.

Les sections suivantes fournissent des informations sur le dimensionnement automatique du AWS Glue streaming.

Activation d'Auto Scaling dans AWS Glue Studio

Dans l'onglet Détails du Job dans AWS Glue Studio, choisissez le type Spark ou Spark Streaming, et la version Glue **Glue 3.0** ou **Glue 4.0**. Ensuite, une case à cocher apparaît sous le Worker type (Type d'employé).

- Sélectionnez l'option Automatically scale the number of workers (Mise à l'échelle automatique du nombre d'employés).
- Configurez le Nombre maximal d'employés pour définir le nombre maximal d'employés pouvant être transférés à l'exécution de la tâche.

Visual
Script
Job details
Runs
Data quality
Schedules

Version Control

Type

The type of ETL job. This is set automatically based on the types of data sources you have selected.

Spark

Glue version [Info](#)
Glue 4.0 - Supports spark 3.3, Scala 2, Python 3

Language
Python 3

Worker type

Set the type of predefined worker that is allowed when a job runs.

G 1X
(4vCPU and 16GB RAM)

☒ **Automatically scale the number of workers**

AWS Glue will optimize costs and resource usage by dynamically scaling the number of workers up and down throughout the job run. Requires Glue 3.0 or later.

Maximum number of workers

The number of workers you want AWS Glue to allocate to this job.

10

Activer Auto Scaling avec la AWS CLI ou le SDK

Pour activer Auto Scaling From the AWS CLI pour l'exécution de votre tâche, exécutez `start-job-run` la configuration suivante :

```
{
  "JobName": "<your job name>",
  "Arguments": {
    "--enable-auto-scaling": "true"
  },
  "WorkerType": "G.2X", // G.1X and G.2X are allowed for Auto Scaling Jobs
}
```

```
"NumberOfWorkers": 20, // represents Maximum number of workers
...other job run configurations...
}
```

Une fois l'exécution de la tâche ETL terminée, vous pouvez également appeler `get-job-run` pour vérifier l'utilisation réelle des ressources de la tâche exécutée en secondes DPU. Remarque : le nouveau champ `n'DPUSeconds` apparaîtra que pour vos tâches par lots dans la AWS Glue version 3.0 ou ultérieure activée avec Auto Scaling. Ce champ n'est pas pris en charge pour les tâches de streaming.

```
$ aws glue get-job-run --job-name your-job-name --run-id jr_xx --endpoint https://
glue.us-east-1.amazonaws.com --region us-east-1
{
  "JobRun": {
    ...
    "GlueVersion": "3.0",
    "DPUSeconds": 386.0
  }
}
```

Vous pouvez également configurer des exécutions de tâches avec Auto Scaling à l'aide du kit [SDK AWS Glue](#) en suivant la même configuration.

Comment ça marche

Mise à l'échelle dans les microlots


L'exemple suivant est utilisé pour décrire le fonctionnement de l'autoscaling.

- Vous avez un AWS Glue travail qui commence à 50 ans DPUs.
- L'autoscaling est activé.

Dans cet exemple, AWS Glue examine la métrique `batchProcessingTime InMs` « » pour quelques microlots et détermine si vos tâches se terminent dans les limites de la fenêtre que vous avez définie. Si vos tâches sont terminées plus tôt et en fonction de la rapidité avec laquelle elles seront terminées, AWS Glue pourra se réduire. Cette métrique, tracée avec `numberAllExecutors` « », peut être surveillée Amazon CloudWatch pour voir comment fonctionne l'autoscaling.

Le nombre de programmes d'exécution augmente ou se réduit de façon exponentielle uniquement après la fin de chaque microlot. Comme vous pouvez le constater dans le journal de Amazon

CloudWatch surveillance, AWS Glue il examine le nombre d'exécuteurs nécessaires (ligne orange) et redimensionne les exécuteurs (ligne bleue) pour qu'ils correspondent automatiquement à ce nombre.



Une AWS Glue fois réduit le nombre d'exécuteurs et constaté que les volumes de données augmentent, ce qui augmente le temps de traitement par microlots, AWS Glue on passe à 50 DPUs, soit la limite supérieure spécifiée.

Mise à l'échelle au sein de microlots

Dans l'exemple ci-dessus, le système surveille quelques microlots terminés pour décider de les augmenter ou de les réduire. Les fenêtres plus longues nécessitent une mise à l'échelle automatique pour réagir plus rapidement au sein du microlot, plutôt que d'attendre quelques microlots. Dans ces cas, vous pouvez utiliser une configuration supplémentaire --auto-scale-within-microbatch pour true. Vous pouvez l'ajouter aux propriétés de la AWS Glue tâche AWS Glue Studio comme indiqué ci-dessous.

Job parameters Info

Key	Value - optional	
--auto-scale-within-microbatch	true	Remove

Add new parameter

You can add 49 more parameters.

Fenêtres de maintenance pour le AWS Glue streaming

AWS Glue effectue périodiquement des activités de maintenance. Au cours de ces fenêtres de maintenance, vous AWS Glue devrez redémarrer vos tâches de streaming. Vous pouvez contrôler le moment où les tâches sont redémarrées en spécifiant des fenêtres de maintenance. Dans cette section, nous expliquons où vous pouvez configurer la fenêtre de maintenance et les comportements spécifiques à prendre en compte.

Rubriques

- [Configuration d'une fenêtre de maintenance](#)
- [Comportement des fenêtres de maintenance](#)
- [Surveillance des jobs](#)
- [Gestion des pertes de données](#)

Configuration d'une fenêtre de maintenance

Vous pouvez configurer une fenêtre de maintenance à l'aide de AWS Glue Studio ou APIs.

Configuration d'une fenêtre de maintenance dans AWS Glue Studio

Vous pouvez spécifier une fenêtre de maintenance sur la page Détails de la tâche de AWS Glue streaming. Vous pouvez spécifier le jour et l'heure en GMT. AWS Glue redémarrera votre travail dans le délai imparti.

Maintenance window

Restart on

Select a day of week ▼

 at

hh

 hours (GMT)

For maintenance reasons, AWS Glue will restart streaming jobs within 3 hours of the specified maintenance window. You have the option to designate the start time in GMT for this maintenance. For more information, refer to documentation.

Configuration d'une fenêtre de maintenance dans l'API

Vous pouvez également configurer la fenêtre de maintenance dans l'API Create Job. Voici un exemple de configuration d'une fenêtre de maintenance via l'API.

```
aws glue create-job --name jobName --role roleArnForTheJob --command  
Name=gluestreaming,ScriptLocation=s3-path-to-the-script --maintenance-window="Sun:10"
```

Voici un exemple de commande :

```
aws glue create-job --name testMaintenance --role arn:aws:iam::012345678901:role/  
Glue_DefaultRole --command Name=gluestreaming,ScriptLocation=s3://glue-example-test/  
example.py --maintenance-window="Sun:10"
```

Comportement des fenêtres de maintenance

AWS Glue passe par une série d'étapes pour décider à quel moment redémarrer une tâche :

1. Lorsqu'une nouvelle tâche de streaming est lancée, vérifiez AWS Glue d'abord si un délai d'expiration est associé à l'exécution de la tâche. Un délai d'attente vous permet de configurer l'heure de fin de la tâche. Si le délai d'expiration est inférieur à 7 jours, la tâche ne sera pas redémarrée.
2. Si le délai d'attente est supérieur à 7 jours, AWS Glue vérifie si la fenêtre de maintenance est configurée pour le travail. Si c'est le cas, cette fenêtre est sélectionnée et la fenêtre est affectée à l'exécution du travail. AWS Glue redémarrera le travail dans les 3 heures suivant la période de maintenance spécifiée. Par exemple, si vous configurez la fenêtre de maintenance pour le lundi à 10 h 00 GMT, vos tâches seront redémarrées entre 10 h 00 GMT et 13 h 00 GMT.
3. Si la fenêtre de maintenance n'est pas configurée, définit AWS Glue automatiquement l'heure de redémarrage sur 7 jours après le début de l'exécution du job. Par exemple, si vous avez lancé votre tâche le 1er juillet 2024 à 00h00 GMT et que vous n'avez pas spécifié de fenêtres de maintenance, votre tâche sera configurée pour redémarrer le 08/07/2024 à 00h00 GMT.

Note

Si vous exécutez déjà des jobs de streaming, cette modification aura un impact sur vous à compter du 1er juillet 2024. Vous aurez jusqu'au 30 juin pour configurer vos fenêtres de maintenance. Après le 1er juillet, toutes les tâches de streaming que vous lancez seront

redémarrées conformément à cette documentation. Si vous avez besoin d'une assistance supplémentaire, vous pouvez contacter le AWS Support.


- Parfois, il AWS Glue se peut que vous ne puissiez pas redémarrer le travail, en particulier lorsque le microlot en cours n'est pas traité. Dans ces cas, le travail ne sera pas interrompu. Dans ces cas, la tâche AWS Glue redémarrera au bout de 14 jours, et dans ce cas, la fenêtre de maintenance n'est pas respectée.

Surveillance des jobs

Vous pouvez surveiller les tâches sur la page AWS Glue Studio Monitoring.

Pour connaître l'heure prévue du prochain redémarrage des tâches de streaming, affichez la colonne du tableau des exécutions de tâches sur la page de surveillance.

- Cliquez sur l'icône en forme d'engrenage en haut à droite du tableau.



Job name	Run status	Data quality status	Type	Start time (Local)	End time (Local)	Run time
auto-dq-test	Succeeded		Glue ETL	04/18/2024 10:23:26	04/18/2024 10:25:02	1 minute

- Faites défiler la page vers le bas et activez la colonne Heure de redémarrage prévue. Les options UTC et heure locale sont disponibles.

worker type

DPU hours

Last modified (Local)

Worker utilization

Data skewness

Start time (UTC)

End time (UTC)

Last modified (UTC)

Data quality

Expected restart time (UTC)

Expected restart time (Local)

Cancel

Confirm

3. Vous pouvez ensuite afficher les colonnes du tableau.

Job runs (14) [Info](#)

Actions ▼

[View CloudWatch logs](#)

[View run details](#)

Filter job runs by property

< 1 2 > ⚙

	Job name ▼	Run status ▼	Type ▼	Start time (Local) ▼	End time (Local) ▼	Expected restart time (Local) ▼
☐	auto-dq-test	✔ Succeeded	Glue ETL	04/18/2024 10:23:26	04/18/2024 10:25:02	-
☐	StreamingTest	🔄 Running	Glue Streaming	04/16/2024 16:32:49	-	04/23/2024 02:00:00
☐	StreamingProd	🔄 Running	Glue Streaming	04/16/2024 13:45:10	-	04/25/2024 05:00:00

La tâche d'origine aura le statut « EXPIRÉ » et la nouvelle instance de tâche aura le statut « EN COURS ». La nouvelle exécution de tâche qui a été redémarrée aura un ID d'exécution sous forme de concaténation de l'ID d'exécution initial et du préfixe « restart_ » représentant le nombre de redémarrages. Par exemple, si l'ID d'exécution initial de la tâche est `j_r_1234`, l'exécution de la tâche redémarrée aura l'ID `j_r1234_restart_1` du premier redémarrage. Le deuxième redémarrage sera `j_r1234_restart_2` pour le deuxième redémarrage et ainsi de suite.

Votre nouvelle tentative ne sera pas affectée en raison des redémarrages. Si une exécution échoue et qu'une nouvelle exécution est lancée en raison d'une nouvelle tentative automatique, le compteur de redémarrage recommencera à 1. Par exemple, si une exécution échoue à `j_r_1234_attempt_3_restart_5`, une nouvelle tentative automatique lancera une nouvelle exécution avec un ID : `j_r_id1_attempt_4` et lorsque cette tentative est redémarrée après 7 jours, le nouvel ID d'exécution sera `j_r_id1_attempt_4_restart_1`.

Gestion des pertes de données

Lors des redémarrages de maintenance, AWS Glue Streaming suit un processus qui garantit l'intégrité des données et la cohérence entre le travail précédent et le travail redémarré. Notez que cela AWS Glue ne garantit pas l'intégrité et la cohérence des données entre les redémarrages des tâches et nous recommandons de prendre en compte l'architecture pour gérer les données dupliquées dans les tâches de streaming.

1. Détection des conditions de redémarrage pour maintenance : le AWS Glue streaming surveille les conditions qui indiquent quand un redémarrage pour maintenance doit être déclenché, par exemple lorsqu'une fenêtre de maintenance est atteinte après 7 jours ou qu'un redémarrage brutal est nécessaire après 14 jours.
2. Invoquer une résiliation progressive : lorsque les conditions de redémarrage pour maintenance sont remplies, AWS Glue Streaming lance un processus de résiliation progressive pour le travail en cours d'exécution. Ce processus comprend les étapes suivantes :
 - a. Arrêter l'ingestion de nouvelles données : la tâche de streaming arrête de consommer les nouvelles données provenant des sources d'entrée (par exemple, les sujets Kafka, les flux Kinesis ou les fichiers).
 - b. Traitement des données en attente : la tâche continue de traiter toutes les données déjà présentes dans ses tampons ou files d'attente internes.
 - c. Validation des décalages et des points de contrôle : la tâche valide les derniers décalages ou points de contrôle vers des systèmes externes (par exemple, Kafka, Kinesis ou Amazon S3)

afin de garantir que la tâche redémarrée puisse reprendre là où la tâche précédente s'était arrêtée.

3. Redémarrage de la tâche : une fois le processus d'arrêt progressif terminé, AWS Glue Streaming redémarre la tâche en utilisant l'état préservé et les points de contrôle. La tâche redémarrée reprend le traitement à partir du dernier décalage ou point de contrôle validé, garantissant ainsi qu'aucune donnée n'est perdue ou dupliquée.
4. Reprise du traitement des données : La tâche redémarrée reprend le traitement des données à partir du point où la tâche précédente s'était arrêtée. Il continue à ingérer les nouvelles données provenant des sources d'entrée, à partir du dernier décalage ou point de contrôle validé, et traite les données conformément à la logique ETL définie.


Avancé AWS Glue concepts de streaming

Dans les applications modernes axées sur les données, l'importance des données diminue au fil du temps et leur valeur passe d'une valeur prédictive à une valeur réactive. Par conséquent, les clients souhaitent traiter les données en temps réel pour prendre des décisions plus rapidement. Lorsqu'il s'agit de flux de données en temps réel, tels que ceux provenant de capteurs IoT, les données peuvent arriver de manière désordonnée ou subir des retards de traitement en raison de la latence du réseau ou d'autres défaillances liées à la source lors de l'ingestion. Dans le cadre du AWS Glue plateforme, AWS Glue Le streaming s'appuie sur ces fonctionnalités pour fournir un ETL de streaming évolutif et sans serveur, alimenté par le streaming structuré Apache Spark, permettant aux utilisateurs de traiter les données en temps réel.

Dans cette rubrique, nous explorerons les concepts et fonctionnalités de streaming avancés de AWS Glue Diffusion en continu.

Considérations temporelles lors du traitement des flux

Il existe quatre notions de temps lors du traitement des flux :



- **Heure de l'événement** : heure de survenue de l'événement. Dans la plupart des cas, ce champ est intégré aux données de l'événement elles-mêmes, à la source.

- **Event-time-window** — L'intervalle de temps entre deux événements. Comme le montre le schéma ci-dessus, W1 correspond à un signal event-time-window de 17h00 à 17h10. Chacun event-time-window est un regroupement de plusieurs événements.
- **Heure de déclenchement** : l'heure de déclenchement contrôle la fréquence du traitement des données et de la mise à jour des résultats. Heure à laquelle le traitement par microlots a commencé.
- **Heure d'ingestion** : heure à laquelle les données du flux ont été ingérées dans le service de streaming. Si l'heure de l'événement n'est pas intégrée à l'événement lui-même, cette heure peut être utilisée pour le fenêtrage dans certains cas.

Fenêtrage


Le fenêtrage est une technique qui permet de regrouper et d'agréger plusieurs événements par event-time-window. Dans les exemples suivants, nous découvrirons les avantages du fenêtrage et les circonstances dans lesquelles vous l'utiliseriez.

Selon le cas d'utilisation métier, Spark prend en charge trois types de fenêtres temporelles.

- **Fenêtre pivotante** : série de tailles fixes qui ne se chevauchent pas et event-time-windows sur lesquelles vous pouvez agréger.
- **Fenêtre défilante** : similaire aux fenêtres bascules en ce sens qu'elles sont « de taille fixe », mais les fenêtres peuvent se chevaucher ou défiler tant que la durée du défilement est inférieure à la durée de la fenêtre elle-même.
- **Fenêtre de session** : commence par un événement de données d'entrée et continue à s'étendre tant qu'elle reçoit des entrées dans un intervalle ou pendant une durée d'inactivité. La longueur d'une fenêtre de session peut être statique ou dynamique, selon les entrées.

Fenêtre bascule

La fenêtre Tumbling est une série de tailles fixes qui ne se chevauchent pas et event-time-windows sur lesquelles vous pouvez agréger. Penchons-nous sur un exemple concret pour comprendre.



La société ABC Auto souhaite réaliser une campagne marketing pour une nouvelle marque de voitures de sport. Elle veut choisir une ville regroupant le plus de fans de voitures de sport. Pour atteindre cet objectif, elle publie une courte publicité de 15 secondes présentant la voiture sur son site Web. Tous les « clics » et la « ville » correspondante sont enregistrés et diffusés en continu. Amazon Kinesis Data Streams Nous voulons compter le nombre de clics dans une fenêtre de 10 minutes et le regrouper par ville pour voir quelle ville est la plus demandée. Voici la sortie de l'agrégation.

window_start_time	window_end_time	city	total_clicks
10/07/2023 17:00:00	10/07/2023 17:10:00	Dallas	75
10/07/2023 17:00:00	10/07/2023 17:10:00	Chicago	10
10/07/2023 17:20:00	10/07/2023 17:30:00	Dallas	20
10/07/2023 17:20:00	10/07/2023 17:30:00	Chicago	50

Comme expliqué ci-dessus, event-time-windows ils sont différents des intervalles de déclenchement. Par exemple, même si votre heure de déclenchement est toutes les minutes, les résultats en sortie n'afficheront que des fenêtres d'agrégation de 10 minutes sans chevauchement. Pour optimiser, il est préférable que l'intervalle de déclenchement soit aligné sur le event-time-window.

Dans le tableau ci-dessus, Dallas a enregistré 75 clics au cours de la fenêtre 17 h 00 – 17 h 10, tandis que Chicago a enregistré 10 clics. De plus, il n'y a aucune donnée pour la fenêtre 17 h 10 – 17 h 20 pour aucune ville, donc cette fenêtre est omise.

Vous pouvez désormais effectuer une analyse plus approfondie de ces données dans l'application d'analytique en aval afin de déterminer la ville la plus privilégiée pour mener la campagne marketing.

Utiliser des fenêtres qui s'enfoncent AWS Glue

1. Créez un Amazon Kinesis Data Streams DataFrame et lisez-le. Exemple :

```
parsed_df = kinesis_raw_df \
    .selectExpr('CAST(data AS STRING)') \
    .select(from_json("data", ticker_schema).alias("data")) \
    .select('data.event_time', 'data.ticker', 'data.trade', 'data.volume',
    'data.price')
```

2. Traitez les données dans une fenêtre bascule. Dans l'exemple ci-dessous, les données sont regroupées en fonction du champ de saisie « event_time » dans des fenêtres bascules de 10 minutes et en écrivant le résultat dans un lac de données Amazon S3.


```
grouped_df = parsed_df \
    .groupBy(window("event_time", "10 minutes"), "city") \
    .agg(sum("clicks").alias("total_clicks"))

summary_df = grouped_df \
    .withColumn("window_start_time", col("window.start")) \
    .withColumn("window_end_time", col("window.end")) \
    .withColumn("year", year("window_start_time")) \
    .withColumn("month", month("window_start_time")) \
    .withColumn("day", dayofmonth("window_start_time")) \
    .withColumn("hour", hour("window_start_time")) \
    .withColumn("minute", minute("window_start_time")) \
    .drop("window")

write_result = summary_df \
    .writeStream \
    .format("parquet") \
    .trigger(processingTime="10 seconds") \
    .option("checkpointLocation", "s3a://bucket-stock-stream/stock-  
stream-catalog-job/checkpoint/") \
    .option("path", "s3a://bucket-stock-stream/stock-stream-catalog-  
job/summary_output/") \
    .partitionBy("year", "month", "day") \
    .start()
```

Fenêtre défilante

Les fenêtres défilantes sont similaires aux fenêtres bascules en ce sens qu'elles sont « de taille fixe », mais les fenêtres peuvent se chevaucher ou défiler tant que la durée du défilement est inférieure à la durée de la fenêtre elle-même. En raison de la nature du défilement, une entrée peut être liée à plusieurs fenêtres.



Pour mieux comprendre, prenons l'exemple d'une banque qui souhaite détecter une éventuelle fraude par carte de crédit. Une application en streaming pourrait surveiller un flux continu de transactions par carte de crédit. Ces transactions pourraient être agrégées dans des fenêtres d'une durée de 10 minutes et toutes les 5 minutes, la fenêtre avancerait, éliminant les 5 minutes de données les plus anciennes et ajoutant les 5 dernières minutes de nouvelles données. Dans chaque fenêtre, les transactions pourraient être regroupées par pays pour vérifier l'absence de schémas suspects, comme une transaction aux États-Unis immédiatement suivie d'une autre en Australie. Par souci de simplicité, qualifions ces transactions de fraude lorsque le montant total des transactions est supérieur à 100 USD. Si un tel schéma est détecté, cela indique une fraude potentielle et la carte pourrait être gelée.

Le système de traitement des cartes de crédit envoie un flux d'événements de transaction à Kinesis pour chaque numéro de carte et pour le pays. Une AWS Glue tâche exécute l'analyse et produit le résultat agrégé suivant.

window_start_time	window_end_time	card_last_four	country	total_amount
10/07/2023 17:00:00	10/07/2023 17:10:00	6544	ETATS-UNIS	85
10/07/2023 17:00:00	10/07/2023 17:10:00	6544	Australie	10
10/07/2023 17:05:45	10/07/2023 17:15:45	6544	ETATS-UNIS	50
10/07/2023 17:10:45	10/07/2023 17:20:45	6544	ETATS-UNIS	50

window_start_time	window_end_time	card_last_four	country	total_amount
10/07/2023 17:10:45	10/07/2023 17:20:45	6544	Australie	150

Sur la base de l'agrégation ci-dessus, vous pouvez voir la fenêtre de 10 minutes défilant toutes les 5 minutes, résumée au montant de la transaction. L'anomalie est détectée dans la fenêtre de 17 h 10 à 17 h 20 lorsqu'il y a une valeur aberrante, c'est-à-dire une transaction de 150\$ en Australie. AWS Glue peut détecter cette anomalie et envoyer un événement d'alarme avec la touche incriminée vers un sujet SNS à l'aide de boto3. De plus, une fonction Lambda peut s'abonner à cette rubrique et prendre des mesures.


Traitement des données dans une fenêtre défilante

La clause `group-by` et la fonction de fenêtre sont utilisées pour implémenter la fenêtre défilante comme indiqué ci-dessous.

```
grouped_df = parsed_df \
    .groupBy(window(col("event_time"), "10 minute", "5 min"), "country",
    "card_last_four") \
    .agg(sum("tx_amount").alias("total_amount"))
```

Fenêtre de session

Contrairement aux deux fenêtres ci-dessus qui ont une taille fixe, la longueur d'une fenêtre de session peut être statique ou dynamique, selon les entrées. Une fenêtre de session commence par un événement de données d'entrée et continue à s'étendre tant qu'elle reçoit des entrées dans un intervalle ou pendant une durée d'inactivité.



Prenons un exemple. La société ABC Hotel souhaite savoir quelle est la période la plus chargée de la semaine et proposer de meilleures offres à ses clients. Dès qu'un invité s'enregistre, une fenêtre de session est ouverte et Spark maintient un état avec agrégation pour cela. `event-time-window` Chaque fois qu'un invité s'enregistre, un événement est généré et envoyé à Amazon Kinesis Data Streams. L'hôtel décide que s'il n'y a pas d'enregistrement pendant une période de 15 minutes, il `event-time-window` peut être fermé. Le prochain `event-time-window` recommencera lors d'un nouvel enregistrement. La sortie ressemble à ce qui suit.

window_start_time	window_end_time	city	total_checkins
2023-07-10 17:02:00	10/07/2023 17:30:00	Dallas	50
2023-07-10 17:02:00	10/07/2023 17:30:00	Chicago	25
10/07/2023 17:40:00	10/07/2023 18:20:00	Dallas	75
10/07/2023 18:50:45	10/07/2023 19:15:45	Dallas	20

Le premier enregistrement a eu lieu à `event_time` = 17:02 (17 h 02). L'agrégation `event-time-window` débutera à 17h02. Cette agrégation se poursuivra tant que nous recevrons les événements dans un délai de 15 minutes. Dans l'exemple ci-dessus, le dernier événement que nous avons reçu a eu lieu à 17 h 15, puis il n'y a eu aucun événement pendant les 15 minutes qui ont suivi. Par conséquent, Spark l'a fermé `event-time-window` à 17 h 15 +15 min = 17 h 30 et l'a défini comme étant de 17 h 02 à 17 h 30. Il a recommencé `event-time-window` à 17 h 47 lorsqu'il a reçu un nouvel événement relatif aux données d'enregistrement.

Traitement des données dans une fenêtre de session

La clause `group-by` et la fonction de fenêtre sont utilisées pour implémenter la fenêtre défilante.

```
grouped_df = parsed_df \
    .groupBy(session_window(col("event_time"), "10 minute"), "city") \
    .agg(count("check_in").alias("total_checkins"))
```

Modes de sortie

Le mode de sortie est le mode dans lequel les résultats de la table illimitée sont écrits sur le récepteur externe. Trois modes sont disponibles. Dans l'exemple suivant, vous comptez les occurrences d'un mot alors que des lignes de données sont diffusées et traitées dans chaque microlot.

- **Mode complet** — L'ensemble du tableau des résultats sera écrit dans le récepteur après chaque traitement par microlots, même si le nombre de mots n'a pas été mis à jour dans le courant event-time-window.
- **Mode d'ajout** : il s'agit du mode par défaut, dans lequel seuls les nouveaux mots et/ou les nouvelles lignes ajoutés à la table de résultats depuis le dernier déclenchement seront écrits dans le récepteur. Ce mode est idéal pour le streaming sans état pour des requêtes telles que `map`, `flatMap`, `filter`, etc.
- **Mode de mise à jour** : seuls les mots et/ou les lignes de la table de résultats qui ont été mis à jour ou ajoutés depuis le dernier déclenchement seront écrits dans le récepteur.


Note

Mode de sortie = la « mise à jour » n'est pas prise en charge pour les fenêtres de session.

Gestion des données tardives et des filigranes

Lorsque vous travaillez avec des données en temps réel, l'arrivée des données peut être retardée en raison de la latence du réseau et de défaillances en amont. Nous avons besoin d'un mécanisme pour effectuer à nouveau l'agrégation des données manquantes event-time-window. Cependant, pour ce faire, l'état doit être maintenu. Dans le même temps, les anciennes données doivent être nettoyées pour limiter la taille de l'état. La version 2.1 de Spark a ajouté la prise en charge d'une fonctionnalité appelée filigrane qui maintient l'état et permet à l'utilisateur de spécifier le seuil pour les données tardives.

En référence à notre exemple de symbole boursier ci-dessus, considérons que le seuil autorisé pour les données tardives ne doit pas dépasser 10 minutes. Pour faire simple, nous supposons que la fenêtre est à bascule, que le symbole est AMZ et que la négociation est BUY.



Dans le schéma ci-dessus, nous calculons le volume total sur une fenêtre bascule de 10 minutes. Nous avons le déclenchement à 17 h 00, 17 h 10 et 17 h 20. Au-dessus de la flèche chronologique, nous avons le flux de données d'entrée et ci-dessous se trouve la table des résultats illimités.

Au cours de la première fenêtre bascule de 10 minutes, nous avons agrégé en fonction de event_time et le total_volume a été calculé comme étant 30. Dans le second cas event-time-window, Spark a obtenu le premier événement de données avec event_time= 17:02. Comme il s'agit de la valeur event_time maximale observée jusqu'à présent par Spark, le seuil du filigrane est défini il y a 10 minutes (c'est-à-dire watermark_event_time = 16:52). Tout événement de données avec un event_time après 16:52 sera pris en compte pour l'agrégation limitée dans le temps et tout événement de données antérieur sera supprimé. Cela permet à Spark de maintenir un état intermédiaire pendant 10 minutes supplémentaires pour tenir compte des données tardives. Vers 17 h 08, durée chronométrée, Spark a reçu un événement avec un event_time = 16:54, ce qui était dans les limites du seuil. Spark a donc recalculé le « 16:50 - 17:00 » event-time-window et le volume total a été mis à jour de 30 à 60.

Cependant, à l'heure de déclenchement 17 h 20, lorsque Spark a reçu un événement avec event_time = 17:15, il a défini le watermark_event_time = 17:05. Par conséquent, l'événement de données tardives avec event_time = 17:03 a été considéré comme « trop tardif » et ignoré.

$$\text{Watermark Boundary} = \text{Max(Event Time)} - \text{Watermark Threshold}$$

Utilisation de filigranes dans AWS Glue

Spark n'émet ni n'écrit les données sur le récepteur externe tant que la limite du filigrane n'est pas dépassée. Pour implémenter un filigrane dans AWS Glue, voir l'exemple ci-dessous.

```
grouped_df = parsed_df \  
    .withWatermark("event_time", "10 minutes") \  
    .groupBy(window("event_time", "5 minutes"), "ticker") \  
    .agg(sum("volume").alias("total_volume"))
```

À propos de la surveillance des jobs de AWS Glue streaming

La surveillance de votre tâche de streaming est un élément essentiel de la création de votre pipeline ETL. Outre l'interface utilisateur Spark, vous pouvez également utiliser Amazon CloudWatch pour surveiller les métriques. Vous trouverez ci-dessous une liste des métriques de streaming émises par le AWS Glue framework. Pour une liste complète de toutes les AWS Glue métriques, consultez la section [Surveillance à AWS Glue l'aide CloudWatch des métriques Amazon](#).

AWS Glue utilise un framework de streaming structuré pour traiter les événements d'entrée. Vous pouvez soit utiliser l'API Spark directement dans votre code, soit tirer parti du `ForEachBatch` fourni par `GlueContext`, qui publie ces métriques. Pour comprendre ces métriques, nous devons d'abord comprendre `windowSize`.

windowSize : `windowSize` est l'intervalle entre les microlots que vous indiquez. Si vous spécifiez une taille de fenêtre de 60 secondes, la tâche de AWS Glue diffusion attendra 60 secondes (ou plus si le lot précédent n'est pas terminé d'ici là) avant de lire les données d'un lot à partir de la source de diffusion et d'appliquer les transformations fournies dans `ForEachBatch`. Cet intervalle est également appelé intervalle de déclenchement.

Passons en revue les métriques plus en détail pour comprendre les caractéristiques de santé et de performance.

Note


Les métriques sont émises toutes les 30 secondes. Si votre `windowSize` est inférieure à 30 secondes, les métriques rapportées sont une agrégation. Supposons, par exemple, que votre `windowSize` soit de 10 secondes et que vous traitiez régulièrement 20 enregistrements par microlot. Dans ce scénario, la valeur métrique émise pour `numRecords` serait de 60.

Aucune métrique n'est émise si aucune donnée n'est disponible pour elle. De plus, dans le cas de la métrique de décalage du consommateur, vous devez activer la fonctionnalité pour obtenir des métriques correspondantes.


Visualisation des statistiques de AWS Glue streaming

Pour tracer des métriques visuelles :

1. Accédez à Metrics dans la CloudWatch console Amazon, puis choisissez l'onglet Parcourir. Choisissez ensuite Glue sous « Espaces de noms personnalisés ».



2. Choisissez Métriques de tâche pour afficher les métriques de toutes vos tâches.
3. Filtrez les métriques en fonction de votre JobName =, glue-feb-monitoring puis de JobRunId =ALL. Vous pouvez cliquer sur le signe « + » comme indiqué dans la figure ci-dessous pour l'ajouter au filtre de recherche.
4. Cochez la case correspondant aux métriques qui vous intéressent. Dans la figure ci-dessous, nous avons sélectionné numberAllExecutors et numberMaxNeededExecutors.



5. Une fois que vous avez sélectionné ces métriques, vous pouvez accéder à l'onglet Graphique des métriques et appliquer vos métriques.
6. Comme les métriques sont émises toutes les minutes, vous pouvez appliquer la « moyenne » sur une minute pour batchProcessingTimeInMs et maxConsumerLagInMs. Pour numRecords, vous pouvez appliquer la « somme » sur chaque minute.
7. Vous pouvez ajouter une annotation windowSize horizontale à votre graphique à l'aide de l'onglet Options.

Browse Query Graphed metrics (1) **Options** Source

Widget type

Line Stacked area Number Gauge Bar Pie

Legend position

☐ Hidden ☒ Bottom ☐ Right

Left Y axis

Label milliseconds

Limits Min Auto Max Auto

☒ Show units

Horizontal annotations / thresholds - New ⓘ

	Label	Value	Fill	Axis	Actions
☒	windowSize	60000	None		✕

Live data

☐ Display most recent data point, even when not yet fully aggregated.


Right Y axis

Label Add custom

Limits Min Auto Max Auto

☒ Show units

8. Une fois que vous avez sélectionné vos métriques, créez un tableau de bord et ajoutez-le. Voici un exemple de tableau de bord.




Utilisation des métriques AWS Glue de streaming

Cette section décrit chacune des métriques et la façon dont elles sont corrélées les unes avec les autres.


Nombre d'enregistrements (métrique : streaming.numRecords)

Cette métrique indique le nombre d'enregistrements en cours de traitement.



Cette métrique de streaming fournit une visibilité sur le nombre d'enregistrements que vous traitez dans une fenêtre. Outre le nombre d'enregistrements en cours de traitement, cela vous aidera également à comprendre le comportement du trafic d'entrée.


- La métrique n° 1 montre un exemple de trafic stable sans pics. Il s'agit généralement d'applications telles que des capteurs IoT qui collectent des données à intervalles réguliers et les envoient à la source de streaming.
- La métrique n° 2 montre un exemple d'augmentation soudaine du trafic sur une charge par ailleurs stable. Cela peut se produire dans une application de flux de clics lors d'un événement marketing tel que le Black Friday et lorsque le nombre de clics augmente.
- La métrique n° 3 montre un exemple de trafic imprévisible. Un trafic imprévisible ne signifie pas qu'il y a un problème. Il s'agit simplement de la nature des données d'entrée. Pour en revenir à l'exemple des capteurs IoT, vous pouvez imaginer des centaines de capteurs qui envoient des événements liés aux changements météorologiques à la source de streaming. Comme les changements météorologiques ne sont pas prévisibles, les données ne le sont pas non plus. Comprendre le modèle de trafic est essentiel pour dimensionner vos programmes d'exécution. Si l'entrée est sujette à des pics de trafic, vous pouvez envisager d'utiliser l'autoscaling (nous y reviendrons plus tard).



Vous pouvez combiner cette métrique avec la PutRecords métrique Kinesis pour vous assurer que le nombre d'événements ingérés et le nombre d'enregistrements lus sont quasiment identiques. Cette approche est utile lorsque vous essayez de comprendre le décalage. Au fur et à mesure que le taux d'ingestion augmente, le temps de numRecords lecture augmente également AWS Glue.

Temps de traitement par lots (métrique : streaming) batchProcessingTimeInMs)

La métrique du temps de traitement par lots vous aide à déterminer si le cluster est sous-provisionné ou suraprovisionné.




Cette métrique indique le nombre de millisecondes nécessaires au traitement de chaque microlot d'enregistrements. L'objectif principal ici est de surveiller ce temps pour s'assurer qu'il est inférieur à l'intervalle `windowSize`. Ce n'est pas grave si le `batchProcessingTimeInMs` est dépassé temporairement, tant qu'il se rétablit dans l'intervalle de fenêtre suivant. La métrique n° 1 indique un temps plus ou moins stable de traitement de la tâche. Toutefois, si le nombre d'enregistrements d'entrée augmente, le temps nécessaire au traitement de la tâche augmentera, comme le montre

la métrique n° 2. Si le numRecords n’augmente pas, mais que le temps de traitement augmente, vous devrez examiner de plus près le traitement des tâches sur les programmes d’exécution. Il est recommandé de définir un seuil et une alerte pour s’assurer que le batchProcessingTimeInMs ne dépasse pas 120 % pendant plus de 10 minutes. Pour plus d'informations sur le paramétrage des alarmes, consultez la section [Utilisation des CloudWatch alarmes Amazon](#).


Retard de consommation (métrique : streaming). maxConsumerLagInMs)

La métrique du décalage de consommateur vous aide à comprendre s’il existe un décalage dans le traitement des événements. Si votre décalage est trop important, vous risquez de ne pas respecter le SLA de traitement dont dépend votre activité, même si vous avez une taille de fenêtre windowSize correcte. Vous devez activer explicitement cette métrique à l’aide de l’option de connexion emitConsumerLagMetrics. Pour de plus amples informations, veuillez consulter [KinesisStreamingSourceOptions](#).



Métriques dérivées

Pour obtenir des informations plus approfondies, vous pouvez créer des indicateurs dérivés afin d'en savoir plus sur vos jobs de streaming sur Amazon CloudWatch.



Vous pouvez créer un graphique avec des mesures dérivées pour décider si vous devez en utiliser davantage DPU. Bien que l'autoscaling vous aide à le faire automatiquement, vous pouvez utiliser des métriques dérivées pour déterminer si l'autoscaling fonctionne efficacement.

- **InputRecordsPerSecond** indique la vitesse à laquelle vous obtenez des enregistrements d'entrée. Il est dérivé comme suit : nombre d'enregistrements d'entrée (Glue.Driver.Streaming.NumRecords)/. WindowSize
- **ProcessingRecordsPerSecond** indique le rythme auquel vos enregistrements sont traités. Il est dérivé comme suit : nombre d'enregistrements d'entrée (Glue.Driver.Streaming.NumRecords)/. batchProcessingTime InMs

Si le taux d'entrée est supérieur au taux de traitement, vous devrez peut-être augmenter la capacité pour traiter votre tâche ou augmenter le parallélisme.


Métriques d'autoscaling

Lorsque votre trafic d'entrée connaît des pics, vous devez envisager d'activer l'autoscaling et de spécifier le nombre maximal de travailleurs. Avec cela, vous obtenez deux métriques supplémentaires, `numberAllExecutors` et `numberMaxNeededExecutors`.

- `numberAllExecutors` est le nombre d'exécuteurs de tâches en cours d'exécution active

- `numberMaxNeeded` Les exécuteurs sont le nombre maximum d'exécuteurs de tâches (en cours d'exécution et en attente) nécessaires pour satisfaire la charge actuelle.

Ces deux métriques vous aideront à déterminer si votre autoscaling fonctionne correctement.



AWS Glue surveillera la `batchProcessingTimeInMs` métrique sur quelques microlots et effectuera l'une des deux opérations suivantes. Il fera monter en puissance le nombre de programmes d'exécution, si `batchProcessingTimeInMs` est plus proche de la `windowSize`, ou mettra à l'échelle horizontale les programmes d'exécution, si `batchProcessingTimeInMs` est comparativement inférieur à `windowSize`. En outre, il utilisera un algorithme pour mettre à l'échelle les programmes d'exécution par étapes.

- La métrique n° 1 vous montre comment les programmes d'exécution actifs augmentent pour rattraper le nombre maximal de programmes d'exécution nécessaires afin de traiter la charge.
- La métrique n° 2 vous montre comment le nombre de programmes d'exécution actifs a été mis à l'échelle horizontale comme le `batchProcessingTimeInMs` était faible.

Vous pouvez utiliser ces métriques pour surveiller le parallélisme actuel au niveau des programmes d'exécution et ajuster le nombre maximal de travailleurs dans votre configuration d'autoscaling en conséquence.

Comment obtenir les meilleures performances

Spark essaiera de créer une tâche par partition, à partir de laquelle lire, dans le flux Amazon Kinesis. Les données de chaque partition deviennent une partition. Il répartira ensuite ces tâches entre les

programmes d'exécution/travailleurs, en fonction du nombre de cœurs de chaque travailleur (le nombre de cœurs par travailleur dépend du type de travailleur que vous sélectionnez, G.025X, G.1X, etc.). Cependant, la façon dont les tâches sont réparties n'est pas déterministe. Toutes les tâches sont exécutées en parallèle sur leurs cœurs respectifs. S'il y a plus de partitions que de cœurs de programme d'exécution disponibles, les tâches sont mises en file d'attente.

Vous pouvez utiliser une combinaison des métriques ci-dessus et du nombre de partitions pour fournir à vos programmes d'exécution une charge stable avec de la place pour les pics. Il est recommandé d'exécuter quelques itérations de votre tâche afin de déterminer le nombre approximatif de travailleurs. Pour une charge de travail instable/sujette aux pics, vous pouvez faire de même en configurant l'autoscaling et le nombre maximal de travailleurs.

Définissez la `windowSize` conformément aux exigences du SLA de votre entreprise. Par exemple, si votre entreprise exige que les données traitées ne soient pas obsolètes de plus de 120 secondes, réglez votre `windowSize` sur au moins 60 secondes afin que le décalage moyen du consommateur soit inférieur à 120 secondes (voir la section sur le décalage du consommateur ci-dessus). À partir de là, en fonction de la quantité `numRecords` et du nombre de fragments, planifiez la capacité en vous DPU assurant que vous `batchProcessingTimeInMs` êtes inférieure à 70 % de votre capacité la `windowSize` plupart du temps.

Note

Les partitions chaudes peuvent provoquer une asymétrie des données, ce qui signifie que certaines partitions sont beaucoup plus grandes que les autres. Certaines tâches exécutées en parallèle peuvent donc prendre plus de temps, ce qui peut entraîner des ralentissements. Par conséquent, le lot suivant ne pourra pas démarrer tant que toutes les tâches du précédent ne seront pas terminées, ce qui aura un impact sur le `batchProcessingTimeInMillis` et le décalage maximal.

Intégrations zéro ETL

[Zero-ETL](#) est un ensemble d'intégrations entièrement gérées AWS qui minimise le besoin de créer des pipelines de données ETL pour les cas d'utilisation courants d'ingestion et de réplication. Il rend les données disponibles dans Amazon SageMaker Lakehouse et Amazon Redshift à partir de multiples sources opérationnelles, transactionnelles et applicatives. Avec l'intégration Zero-ETL, vous disposez de données plus récentes pour l'analyse, l'IA/ML et le reporting. Vous obtenez des informations plus précises et plus opportunes pour des cas d'utilisation tels que les tableaux de bord commerciaux, l'optimisation de l'expérience de jeu, le suivi de la qualité des données et l'analyse du comportement des clients. Vous pouvez établir des prévisions basées sur les données en toute confiance, améliorer l'expérience client et promouvoir des informations basées sur les données dans l'ensemble de l'entreprise.

Amazon Redshift est un service d'entrepôt de données rapide, entièrement géré et doté d'une capacité de plusieurs pétaoctets. Il permet d'analyser de manière efficace, simple et économique toutes vos données grâce à vos outils d'informatique décisionnelle existants.

Amazon SageMaker Lakehouse unifie toutes vos données entre les lacs de données Amazon Simple Storage Service (S3) et les entrepôts de données Amazon Redshift, vous aidant ainsi à créer de puissantes analyses et AI/ML applications à partir d'une seule copie des données. SageMaker Lakehouse vous donne la flexibilité d'accéder à vos données et de les interroger sur place avec tous les outils et moteurs compatibles avec Apache Iceberg. Avec SageMaker Lakehouse, vous avez également la flexibilité d'accéder à vos données et de les interroger sur place à l'aide d'outils et de moteurs compatibles avec Apache Iceberg. En outre, vous pouvez sécuriser vos données grâce à des contrôles d'accès intégrés et précis, qui sont appliqués à toutes vos données dans tous les outils et moteurs d'analyse. Définissez les autorisations une seule fois et partagez les données en toute confiance au sein de votre organisation.

Fonctionnalités zéro ETL dans AWS Glue

Les intégrations sans ETL AWS Glue simplifient l'ingestion et la réplication des données depuis les services de AWS données et les applications tierces vers AWS les destinations.

AWS les services pris en charge par des sources zéro ETL AWS Glue incluent :

- Amazon DynamoDB

Les applications tierces prises en charge par Zero-ETL incluent :

- Facebook Ads
- Instagram Ads
- Salesforce
- Engagement avec le compte Salesforce Marketing Cloud
- SAP OData
- ServiceNow
- Zendesk
- Zoho CRM

AWS les services pris en charge par des cibles zéro ETL AWS Glue incluent :

- Amazon Redshift
- Amazon SageMaker Lakehouse

 Note

Lorsque vous créez une intégration zéro ETL avec une AWS Glue source Amazon DynamoDB dans, la cible est prise en charge par Amazon Lakehouse. SageMaker

Conditions préalables à la configuration d'une intégration zéro ETL

La configuration d'une intégration entre la source et la cible nécessite certaines conditions préalables, telles que la configuration des rôles IAM qui AWS Glue permettent d'accéder aux données depuis la source et d'écrire sur la cible, et l'utilisation de clés KMS pour chiffrer les données à l'emplacement intermédiaire ou cible.

Rubriques

- [Configuration des ressources sources](#)
- [Configuration des ressources cibles](#)
- [Création d'un entrepôt de données Amazon Redshift](#)
- [Configuration d'un VPC pour votre intégration zéro ETL](#)

- [Configuration d'une intégration entre comptes zéro ETL](#)

Configuration des ressources sources

Effectuez les tâches de configuration suivantes selon les besoins de votre source.

Configuration du rôle source

Cette section décrit comment transmettre un rôle source pour permettre à l'intégration Zero-ETL d'accéder à votre connexion. Cela s'applique également uniquement aux sources SaaS.

Note

Pour limiter l'accès à quelques connexions uniquement, vous pouvez d'abord créer la connexion pour obtenir l'ARN de connexion. Consultez [Configuration d'une source pour une intégration zéro ETL](#).

Créez un rôle autorisé à accéder à la connexion pour l'intégration :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "GlueConnections",
      "Effect": "Allow",
      "Action": [
        "glue:GetConnections",
        "glue:GetConnection"
      ],
      "Resource": [
        "arn:aws:glue:*:<accountId>:catalog",
        "arn:aws:glue:us-east-1:<accountId>:connection/*"
      ]
    },
    {
      "Sid": "GlueActionBasedPermissions",
      "Effect": "Allow",
      "Action": [
        // Fetch entities:
        "glue:ListEntities",
```

```

        // Refresh connection credentials:
        "glue:RefreshOAuth2Tokens"
    ],
    "Resource": [
        "*"
    ]
}
]
}

```

Stratégie d'approbation :

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": [
          "glue.amazonaws.com"
        ]
      },
      "Action": "sts:AssumeRole"
    }
  ]
}

```

Configuration des ressources cibles

Effectuez les tâches de configuration suivantes selon les besoins pour AWS Glue la cible d'intégration du catalogue de Amazon Redshift données ou de l'entrepôt de données.

Pour les intégrations avec une cible AWS Glue de base de données :

- [Configuration d'une AWS Glue base de données](#)
- [Fournir une politique d'accès basé sur les ressources \(RBAC\) au catalogue](#)
- [Création d'un rôle IAM cible](#)

Pour les intégrations avec une cible d' Amazon Redshift entrepôt de données :

- <https://docs.aws.amazon.com/glue/latest/dg/zero-etl-prerequisites.html#zero-etl-setup-target-redshift-data-warehouse>

Configuration d'une AWS Glue base de données

Pour les intégrations qui utilisent une AWS Glue base de données :

Pour configurer une base de données cible dans le catalogue de AWS Glue données avec un emplacement Amazon S3 :

1. Sur la page d'accueil de la AWS Glue console, sélectionnez Base de données sous Catalogue de données.
2. Choisissez Ajouter une base de données dans le coin supérieur droit. Si vous avez déjà créé une base de données, assurez-vous que l'emplacement avec l'URI Amazon S3 est défini pour la base de données.
3. Entrez un nom et un emplacement (URI Amazon S3). Notez que l'emplacement est requis pour l'intégration zéro ETL. Cliquez sur Créer une base de données lorsque vous avez terminé.

Note

Le compartiment Amazon S3 doit se trouver dans la même région que la AWS Glue base de données.

Pour plus d'informations sur la création d'une nouvelle base de données dans AWS Glue, voir [Mise en route avec le catalogue de AWS Glue données](#).

Vous pouvez également utiliser la [create-database](#) CLI pour créer la base de données dans AWS Glue. Notez que l'LocationUri entrée --database-input est obligatoire.

Optimisation des tables Iceberg

Une fois qu'une table est créée AWS Glue dans la base de données cible, vous pouvez activer le compactage pour accélérer les requêtes dans Amazon Athena. Pour plus d'informations sur la configuration des ressources (rôle IAM) pour le compactage, consultez la section Conditions préalables à l'[optimisation des tables](#).

Pour plus d'informations sur la configuration du compactage sur la AWS Glue table créée par l'intégration, consultez [Optimisation des tables Iceberg](#).

Fournir une politique d'accès basé sur les ressources (RBAC) au catalogue

Pour les intégrations qui utilisent une AWS Glue base de données, ajoutez les autorisations suivantes à la politique RBAC du catalogue afin de permettre les intégrations entre la source et la cible.

Note

Pour les intégrations entre comptes, la politique de rôle d'Alice (utilisateur créant l'intégration) et la politique de ressources du catalogue doivent autoriser l'accès à `glue:CreateInboundIntegration` la ressource. Pour un même compte, une politique de ressources ou une politique de rôle autorisant `glue:CreateInboundIntegration` la ressource est suffisante. Les deux scénarios doivent encore être `glue.amazonaws.com` autorisés `glue:AuthorizeInboundIntegration`.

Vous pouvez accéder aux paramètres du catalogue sous Catalogue de données. Fournissez ensuite les autorisations suivantes et complétez les informations manquantes.

```
{
  "Version": "2012-10-17",
  "Statement": [
    { // Allow Alice to create Integration on Target Database
      "Principal": {
        "AWS": [
          "arn:aws:iam::<source-account-id>:user/Alice"
        ]
      },
      "Effect": "Allow",
      "Action": [
        "glue:CreateInboundIntegration"
      ],
      "Resource": [
        "arn:aws:glue:<region>:<Target-Account-Id>:catalog",
        "arn:aws:glue:<region>:<Target-Account-Id>:database/DatabaseName"
      ],
      "Condition": {
        "StringLike": {
          "aws:SourceArn": "arn:aws:dynamodb:<region>:<Account>:table/<table-name>"
        }
      }
    ]
  },
}
```

```
{ // Allow Glue to Authorize the Inbound Integration on behalf of Bob
  "Principal": {
    "Service": [
      "glue.amazonaws.com"
    ]
  },
  "Effect": "Allow",
  "Action": [
    "glue:AuthorizeInboundIntegration"
  ],
  "Resource": [
    "arn:aws:glue:<region>:<Target-Account-Id>:catalog",
    "arn:aws:glue:<region>:<Target-Account-Id>:database/DatabaseName"
  ],
  "Condition": {
    "StringEquals": {
      "aws:SourceArn": "arn:aws:dynamodb:<region>:<account-id>:table/<table-name>"
    }
  }
}
```

Création d'un rôle IAM cible

Créez un rôle IAM cible avec les autorisations et les relations de confiance suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Action": "s3:ListBucket",
      "Resource": "arn:aws:s3:::<target iceberg table s3 bucket>",
      "Effect": "Allow"
    },
    {
      "Action": [
        "s3:GetObject",
        "s3:PutObject",
        "s3:DeleteObject"
      ],
      "Resource": "arn:aws:s3:::<target iceberg table s3 bucket>/prefix/*",
      "Effect": "Allow"
    }
  ]
}
```

```

    },
    {
      "Action": [
        "glue:GetDatabase"
      ],
      "Resource": [
        "arn:aws:glue:<region>:<account-id>:catalog",
        "arn:aws:glue:<region>:<account-id>:database/DatabaseName"
      ],
      "Effect": "Allow"
    },
    {
      "Action": [
        "glue:CreateTable",
        "glue:GetTable",
        "glue:UpdateTable",
        "glue:GetTableVersion",
        "glue:GetTableVersions",
        "glue:GetResourcePolicy"
      ],
      "Resource": [
        "arn:aws:glue:<region>:<account-id>:catalog",
        "arn:aws:glue:<region>:<account-id>:database/<DatabaseName>",
        "arn:aws:glue:<region>:<account-id>:table/<DatabaseName>/*"
      ],
      "Effect": "Allow"
    },
    {
      "Action": [
        "cloudwatch:PutMetricData"
      ],
      "Resource": "*",
      "Condition": {
        "StringEquals": {
          "cloudwatch:namespace": "AWS/Glue/ZeroETL"
        }
      },
      "Effect": "Allow"
    },
    {
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
      ]
    }
  ]
}

```

```
    ],
    "Resource": "*",
    "Effect": "Allow"
  }
]
```

Ajoutez la politique de confiance suivante pour permettre au AWS Glue service d'assumer le rôle :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

Création d'un entrepôt de données Amazon Redshift

Lorsque votre objectif d'intégration zéro ETL est un entrepôt de données Amazon Redshift, créez-le si vous n'en avez pas déjà un. Pour créer un groupe de travail Amazon Redshift Serverless, consultez [Création d'un groupe de travail avec un espace de noms](#). Pour créer un cluster Amazon Redshift, consultez [Création d'un cluster](#).

Le `enable_case_sensitive_identifier` paramètre doit être activé dans le Amazon Redshift groupe de travail ou le cluster cible pour que l'intégration soit réussie. Pour plus d'informations sur l'activation de la distinction majuscules/minuscules, consultez la section [Activer la distinction majuscules/minuscules pour votre entrepôt de données](#) dans le guide de gestion Amazon Redshift.

Une fois la configuration Amazon Redshift du groupe de travail ou du cluster terminée, vous devez configurer votre entrepôt de données. Pour plus d'informations, reportez-vous à la section [Getting started with zero-ETL integrations](#) dans le Guide de Amazon Redshift gestion.

Configuration d'un VPC pour votre intégration zéro ETL

Pour configurer un VPC pour votre intégration Zero-ETL :

1. Accédez à VPC > Votre VPCs et choisissez Create VPC.
 - a. Sélectionnez VPC et plus encore.
 - b. Définissez le nom de votre VPC.
 - c. Définissez le IPv4 CIDR : 10.0.0.0/16.
 - d. Réglez le nombre de AZ sur 1.
 - e. Définissez le nombre de sous-réseaux publics et privés sur 1.
 - f. Définissez les passerelles NAT sur None.
 - g. Définissez les points de terminaison VPC sur S3 Gateway.
 - h. Activez les noms d'hôte DNS et la résolution DNS.
2. Accédez à Endpoints et choisissez Create Endpoint.
3. Créez des points de terminaison pour ces services dans le sous-réseau privé de votre VPC (utilisez le groupe de sécurité par défaut) :
 - a. com.amazonaws.us-east-1.lambda
 - b. com.amazonaws.us-east-1.glue
 - c. com.amazonaws.us-east-1.sts

Créez la AWS Glue connexion :

1. Accédez à AWS Glue> Connexions de données et choisissez Créer une connexion.
2. Sélectionnez Réseau.
3. Sélectionnez le VPC, le sous-réseau (privé) et le groupe de sécurité par défaut que vous avez créés.

Configuration du rôle cible pour le VPC

Le rôle cible doit disposer des autorisations suivantes (en plus des autres autorisations requises par les ETI intégrations Zéro) :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "CustomerVpc",
      "Effect": "Allow",
      "Action": [
```

```

        "ec2:CreateTags",
        "ec2:DeleteTags",
        "ec2:DescribeRouteTables",
        "ec2:DescribeVpcEndpoints",
        "ec2:DescribeSecurityGroups",
        "ec2:DescribeSubnets",
        "ec2:CreateNetworkInterface",
        "ec2:DeleteNetworkInterface",
        "glue:GetConnection"
    ],
    "Resource": [
        "*"
    ]
}
]
}

```

Configuration des propriétés des ressources du segment cible

Si vous utilisez la CLI, définissez les propriétés des ressources du segment cible sur la AWS Glue base de données cible que vous avez créée. Transmettez l'ARN du rôle cible, ainsi que le nom de la AWS Glue connexion.

```

aws glue create-integration-resource-property \
--resource-arn arn:aws:glue:us-east-1:<account-id>:database/exampltarget \
--target-processing-properties '{"RoleArn" : "arn:aws:iam::<account-id>:role/example-role", "ConnectionName":"example-vpc-3"}' \
--endpoint-url https://example.amazonaws.com --region us-east-1

```

Erreurs possibles du client

Les erreurs client possibles associées à une intégration configurée avec un VPC sont les suivantes.

Message d'erreur	Action requise
Le rôle fourni n'est pas autorisé à effectuer du collage : GetConnection lors de la connexion. Ajoutez cette autorisation à la politique de rôle, puis attendez que l'intégration soit rétablie.	Mettre à jour la politique de rôle

Message d'erreur	Action requise
Le rôle fourni n'est pas autorisé à exécuter <code>ec2:DescribeSubnets</code> . Ajoutez cette autorisation à la politique de rôle, puis attendez que l'intégration soit rétablie.	Mettre à jour la politique de rôle
Le rôle fourni n'est pas autorisé à exécuter <code>ec2:DescribeSecurityGroups</code> . Ajoutez cette autorisation à la politique de rôle, puis attendez que l'intégration soit rétablie.	Mettre à jour la politique de rôle
Le rôle fourni n'est pas autorisé à exécuter <code>ec2:DescribeVpcEndpoints</code> . Ajoutez cette autorisation à la politique de rôle, puis attendez que l'intégration soit rétablie.	Mettre à jour la politique de rôle
Le rôle fourni n'est pas autorisé à exécuter <code>ec2:DescribeRouteTables</code> . Ajoutez cette autorisation à la politique de rôle, puis attendez que l'intégration soit rétablie.	Mettre à jour la politique de rôle
Le rôle fourni n'est pas autorisé à exécuter <code>ec2:CreateTags</code> . Ajoutez cette autorisation à la politique de rôle, puis attendez que l'intégration soit rétablie.	Mettre à jour la politique de rôle
Le rôle fourni n'est pas autorisé à exécuter <code>ec2:CreateNetworkInterface</code> . Ajoutez cette autorisation à la politique de rôle, puis attendez que l'intégration soit rétablie.	Mettre à jour la politique de rôle
Le sous-réseau de connexion fourni ne contient pas de point de terminaison S3 ou de passerelle NAT valide. Mettez à jour le sous-réseau, puis attendez que l'intégration soit rétablie.	Mettre à jour les points de terminaison du sous-réseau VPC

Message d'erreur	Action requise
Sous-réseau de connexion introuvable. Mettez à jour le sous-réseau de connexion, puis attendez que l'intégration soit rétablie.	Mettre à jour AWS Glue la connexion
Groupe de sécurité de connexion introuvable. Mettez à jour le groupe de sécurité de connexion, puis attendez que l'intégration soit rétablie.	Mettre à jour AWS Glue la connexion
Impossible de se connecter à S3 via la connexion VPC fournie. Mettez à jour les configurations de sous-réseau, puis attendez que l'intégration soit rétablie.	Mettre à jour les points de terminaison du sous-réseau VPC
Impossible de se connecter à Lambda via la connexion VPC fournie. Mettez à jour les configurations de sous-réseau, puis attendez que l'intégration soit rétablie.	Mettre à jour les points de terminaison du sous-réseau VPC

Configuration d'une intégration entre comptes zéro ETL

Pour configurer une intégration entre comptes zéro ETL :

1. Configurez une politique de ressources cible comme décrit dans [Fournir une politique d'accès basé sur les ressources \(RBAC\) au catalogue](#). Assurez-vous que le rôle du compte source est explicitement autorisé sur la ressource cible.
2. Vérifiez que le rôle du compte source (le rôle utilisé pour créer l'intégration) possède les caractéristiques suivantes :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "Stmt123456789012",
      "Action": [
        "glue:CreateInboundIntegration"
      ]
    }
  ]
}
```

```

    ],
    "Effect": "Allow",
    "Resource": [
        "arn:aws:glue:<region>:<target-account-id>:catalog",
        "arn:aws:glue:<region>:<target-account-id>:database/DatabaseName"
    ]
  }]
}

```

3. Créez l'intégration comme décrit dans [Création d'une intégration](#).

Configuration d'une source pour une intégration zéro ETL

Support pour les entités SAP spéciales

Pour la plupart des entités SaaS, nous déterminons les ensembles de clés primaires valides lors du traitement des données, mais certaines nécessitent une étape supplémentaire consistant à fournir le jeu de clés primaires valide en entrée, en particulier les entités SAP qui commencent par `EntityOf`. Lorsqu'une `EntityOf` entité est sélectionnée, vous êtes invité à fournir le jeu de clés primaires.

Settings (1)

Configure settings for the selected source data. You can add or delete source data in the source details section above.

Find objects			< 1 >
Selected source data	Primary keys	Partition keys	
/sap/opu/odata/sap/ZCUSTOMER_ATTR_1_SRV/EntityOf0CUSTOMER_ATTR	No primary keys selected	Default partition key	

Configuration d'une source Amazon DynamoDB

Pour accéder aux données de votre table Amazon DynamoDB source AWS Glue, vous devez avoir accès à la description de la table et à l'exportation des données depuis celle-ci. Amazon DynamoDB a récemment introduit une fonctionnalité qui permet de configurer une politique d'accès basé sur les ressources (RBAC).

L'exemple de politique d'accès basé sur les ressources (RBAC) suivant utilise un caractère générique (*) pour l'intégration :

```

{
  "Version": "2012-10-17",

```

```

    "Statement": [{
      "Sid": "1111",
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Resource": "*",
      "Action": [
        "dynamodb:ExportTableToPointInTime",
        "dynamodb:DescribeTable",
        "dynamodb:DescribeExport"
      ],
      "Condition": {
        "StringEquals": {
          "aws:SourceAccount": "<account-id>"
        },
        "StringLike": {
          "aws:SourceArn": "arn:aws:glue:<region>:<account-id>:integration:*"
        }
      }
    }]
  }
}

```

1. Pour la DynamoDB que vous souhaitez répliquer, collez le modèle de politique RBAC ci-dessus dans la politique basée sur les ressources pour la table et renseignez les champs.
2. Si vous souhaitez rendre la politique restrictive, vous devez la mettre à jour après avoir créé l'intégration, spécifier la version complète `integrationArn` et utiliser la `StringEquals` condition à la place de `StringLike`.
3. Assurez-vous que la Point-in-time restauration (PITR) est activée pour la table DynamoDB.
4. Assurez-vous d'ajouter `Describe Export` à la politique d'accès basé sur les ressources (RBAC).

Vous pouvez également ajouter la politique RBAC au tableau à l'aide de la commande suivante :

```

aws dynamodb put-resource-policy \
--resource-arn arn:aws:dynamodb:<region>:<account-id>:table/<dynamodb-table-name> \
--policy file://resource-policy-with-condition.json \
--region <region>

```

Pour vérifier que la politique est correctement appliquée, utilisez la commande suivante pour obtenir la politique de ressources d'une table :

```
aws dynamodb get-resource-policy \  
--resource-arn arn:aws:dynamodb:<region>:<account-id>:table/<ddb-table-name>  
--region <region>
```

Configuration d'une source Salesforce

Pour créer une connexion pour une source Salesforce, consultez [Connexion à Salesforce](#).

Une fois que vous avez créé la connexion, vous pouvez spécifier les données source à répliquer.

Step 1

Select source type

Step 2

Configure source and target

Step 3

Configure integration

Step 4

Review and create

Configure source and target

Source details

Configure the details for your destination in your AWS Glue zero-ETL integration.

Source type

Salesforce

Salesforce connection

Choose the AWS Glue connection for Salesforce, or [create a new connection](#).

SalesforceConnection0731

Source IAM role

Choose an IAM role to associate with your source data, or [create a new one](#).

admin_jad_role

View

Select source data

Select source data to add to this data pipeline.

Salesforce objects (36)

Q contact X

< 1 2 3 4 5 6 7 8 >

Object name	Number of fields	Action
AccountContactRole	11	Preview
AccountContactRoleChangeEvent	11	Preview
CaseContactRole	10	Preview
Contact	63	Preview
ContactCenterChannel	11	Preview

Select all objects

Select all objects across all pages in this table. This action cannot be undone after creating this integration.

Selected source data (3)

Account X

Contact X

Lead X

À l'aide de votre intégration Zero-ETL, vous pouvez effectuer des opérations DDL pour les entités prises en charge. Pour obtenir la liste des entités non prises en charge, consultez [Entités et champs non pris en charge pour Salesforce](#).

Configuration d'une source d'engagement de compte Salesforce Marketing Cloud

Pour créer une connexion pour une source d'engagement de compte Salesforce Marketing Cloud, consultez [Connexion à Salesforce Marketing Cloud Account Engagement](#) .

Source Salesforce

1930

À l'aide de votre intégration Zero-ETL, vous pouvez effectuer des opérations DDL pour les entités prises en charge suivantes :

Libellé de l'entité	Nom de l'entité
Campagne	campaign
Liste	list
Contenu dynamique	contenu dynamique
Adhésion à la liste	adhésion à une liste
Prospect	perspective
Utilisateur	utilisateur
EmailTemplate	modèle d'e-mail
EngagementStudioProgram	engagement-studio-program
Page de destination	page de destination
Adresse e-mail de la liste	liste-e-mail

Configuration supplémentaire de Salesforce

Salesforce Zero-ETL a besoin de l'autorisation Lake Formation sur la base IngestionFailed de données Glue, sinon le journal affichera l'erreur suivante :

```
"errorMessage": "Insufficient lake formation permissions on Target Glue database."
```

Configuration d'une OData source SAP

Pour créer une connexion pour une OData source SAP, consultez [Connexion à SAP OData](#) .

Le OData connecteur SAP dans une intégration zéro ETL ne prend pas en charge les entités commençant EntityOf par.

Configuration d'une ServiceNow source

Pour créer une connexion pour une ServiceNow source, consultez [Connexion à ServiceNow](#).

Configuration d'une source Zendesk

Pour créer une connexion pour une source Zendesk, consultez [Connexion à Zendesk](#).

À l'aide de votre intégration Zero-ETL, vous pouvez effectuer les opérations DDL suivantes pour les entités prises en charge :

Libellé de l'entité	Nom de l'entité	Création prise en charge	Mise à jour supportée	Suppression prise en charge
Tickets	billets	Y	Y	Y
Utilisateur	utilisateurs	Y	Y	Y
Cote de satisfaction	cote de satisfaction	Y	Y	N
Articles	articles	Y	Y	N
Organisation	organisations	Y	Y	Y
Calls	appels	Y	Y	N
Jambes d'appel	jambes	Y	Y	N

Configuration d'une source Zoho CRM

Pour créer une connexion pour une source Zoho CRM, consultez [Connexion à Zoho CRM](#).

À l'aide de votre intégration Zero-ETL, vous pouvez effectuer les opérations DDL suivantes pour les entités prises en charge :

Libellé de l'entité	Nom de l'entité	Insertion DML prise en charge	Prise en charge de la modification DML	Suppression DML prise en charge	DDL-Insert pris en charge	DDL-Modify pris en charge	Suppression DDL prise en charge
Prospects	lead	Y	Y	Y	Y	Y	Y
Comptes	compte	Y	Y	Y	Y	Y	Y
Contacts	contact	Y	Y	Y	Y	Y	Y
Campagnes	campaign	Y	Y	Y	Y	Y	Y
Tâches	tâche	Y	Y	Y	Y	Y	Y
Événements	event	Y	Y	Y	Y	Y	Y
Calls	appel	Y	Y	Y	Y	Y	Y
Solutions	solution	Y	Y	Y	Y	Y	Y
Produits	produit	Y	Y	Y	Y	Y	Y
Vendeurs	fournisseur	Y	Y	Y	Y	Y	Y
Citations	citation	Y	Y	Y	Y	Y	Y
Commande de vente	commande de vente	Y	Y	Y	Y	Y	Y
Bons de commande	bon de commande	Y	Y	Y	Y	Y	Y
Factures	facture	Y	Y	Y	Y	Y	Y
Cas	cas	Y	Y	Y	Y	Y	Y

Libellé de l'entité	Nom de l'entité	Insertion DML prise en charge	Prise en charge de la modification DML	Suppression DML prise en charge	DDL-Insert pris en charge	DDL-Modify pris en charge	Suppression DDL prise en charge
Livres de prix	livre de prix	Y	Y	Y	Y	Y	Y

Configuration d'une source de publicités Facebook

Pour créer une connexion pour une source Facebook Ads, consultez [Connexion aux publicités Facebook](#).

À l'aide de votre intégration Zero-ETL, vous pouvez effectuer les opérations DDL suivantes pour les entités prises en charge :

Libellé de l'entité	Nom de l'entité	Création prise en charge	Mise à jour supportée	Suppression prise en charge
Adset	*/actifs	Y	Y	Y
Campagne	*/campagnes	Y	Y	Y
Publicités	*/annonces	Y	Y	Y

Configuration d'une source d'annonces Instagram

Pour créer une connexion pour une source Instagram Ads, consultez [Connexion aux publicités Instagram](#).

À l'aide de votre intégration Zero-ETL, vous pouvez effectuer les opérations DDL suivantes pour les entités prises en charge :

Nom de l'entité	Création prise en charge	Mise à jour supportée	Suppression prise en charge
*/actifs	Y	Y	Y
*/campagnes	Y	Y	Y
*/annonces	Y	Y	Y

Entités et champs non pris en charge pour Salesforce

Les entités ou champs Salesforce suivants ne sont pas pris en charge pour une utilisation dans le cadre d'une intégration zéro ETL avec une source Salesforce.

AccountChangeEvent, AccountContactRoleChangeEvent, AccountHistory, AccountShare, ActiveFeatureLicenseMetric, ActivePermSetLicenseMetric, ActiveProfileMetric, ActivityFieldHistory, amzsec__asi_Telemetry_Data_Store__ChangeEvent, amzsec__asi_Telemetry_Data_Store__History, amzsec__asi_Telemetry_Data_Store__Share, amzsec__asi_Telemetry_Job_Log__ChangeEvent, amzsec__asi_Telemetry_Job_Log__History, amzsec__asi_Telemetry_Job_Log__Share, amzsec__asi_Telemetry_Requirement__ChangeEvent, amzsec__asi_Telemetry_Requirement__History, amzsec__asi_Telemetry_Requirement__Share, ApexClass, ApexComponent, ApexLog, ApexPage, ApexTestQueueItem, ApexTestResult, ApexTrigger, AssetChangeEvent, AssetHistory, AssetRelationshipHistory, AssetShare, AssignmentRule, AssociatedLocationHistory, AsyncApexJob, AuditTrailFileExportShare, AuthorizationFormConsentChangeEvent, AuthorizationFormConsentHistory, AuthorizationFormConsentShare, AuthorizationFormDataUseHistory, AuthorizationFormDataUseShare, AuthorizationFormHistory, AuthorizationFormShare, AuthorizationFormTextHistory, AuthProvider, AuthSession, BatchJobHistory, BatchJobPartFailedRecordHistory, BatchJobPartHistory, BatchJobShare, BrandTemplate, BriefcaseAssignmentChangeEvent, BriefcaseDefinitionChangeEvent, BusinessBrandShare, BusinessHours, BusinessProcess, CalcMatrixColumnRangeHistory, CalcProcStepRelationshipHistory, CalculationMatrixColumnHistory, CalculationMatrixHistory, CalculationMatrixRowHistory, CalculationMatrixShare, CalculationMatrixVersionHistory, CalculationProcedureHistory, CalculationProcedureShare, CalculationProcedureStepHistory, CalculationProcedureVariableHistory, CalculationProcedureVersionHistory, Calendar, CalendarViewShare, CallCenter, CallCoachConfigModifyEvent, CampaignChangeEvent, CampaignHistory, CampaignMemberChangeEvent, CampaignMemberStatusChangeEvent, CampaignShare, CaseChangeEvent, CaseHistory, CaseHistory2, CaseHistory2ChangeEvent, CaseRelatedIssueChangeEvent, CaseRelatedIssueHistory, CaseShare, CaseStatus, CaseTeamMember, CaseTeamRole, CaseTeamTemplate, CaseTeamTemplateMember,

CaseTeamTemplateRecord, CategoryNode, ChangeRequestChangeEvent, ChangeRequestHistory, ChangeRequestRelatedIssueChangeEvent, ChangeRequestRelatedIssueHistory, ChangeRequestRelatedItemChangeEvent, ChangeRequestRelatedItemHistory, ChangeRequestShare, ChatRetirementRdyMetrics, ChatterActivity, ClientBrowser, CollaborationGroup, CollaborationGroupMember, CollaborationGroupMemberRequest, CollaborationInvitation, CommSubscriptionChannelTypeHistory, CommSubscriptionChannelTypeShare, CommSubscriptionConsentChangeEvent, CommSubscriptionConsentHistory, CommSubscriptionConsentShare, CommSubscriptionHistory, CommSubscriptionShare, CommSubscriptionTimingHistory, Community, ConnectedApplication, ContactChangeEvent, ContactHistory, ContactPointAddressChangeEvent, ContactPointAddressHistory, ContactPointAddressShare, ContactPointConsentChangeEvent, ContactPointConsentHistory, ContactPointConsentShare, ContactPointEmailChangeEvent, ContactPointEmailHistory, ContactPointEmailShare, ContactPointPhoneChangeEvent, ContactPointPhoneHistory, ContactPointPhoneShare, ContactPointTypeConsentChangeEvent, ContactPointTypeConsentHistory, ContactPointTypeConsentShare, ContactRequestShare, ContactShare, ContentDocumentChangeEvent, ContentDocumentHistory, ContentDocumentLink, ContentDocumentLinkChangeEvent, ContentDocumentSubscription, ContentFolderItem, ContentFolderLink, ContentFolderMember, ContentNote, ContentNotification, ContentTagSubscription, ContentUserSubscription, ContentVersionChangeEvent, ContentVersionComment, ContentVersionHistory, ContentVersionRating, ContentWorkspace, ContentWorkspaceMember, ContentWorkspacePermission, ContentWorkspaceSubscription, ContractChangeEvent, ContractHistory, ContractLineItemChangeEvent, ContractLineItemHistory, ContractStatus, Conversation, ConversationParticipant, CronJobDetail, CronTrigger, CustomBrand, CustomBrandAsset, CustomerShare, CustomHTTPHeader, DashboardComponent, DataUseLegalBasisHistory, DataUseLegalBasisShare, DataUsePurposeHistory, DataUsePurposeShare, DecisionTableRecordset, DeleteEvent, DocumentAttachmentMap, Domain, DomainSite, DTRecordsetReplicaShare, EmailBounceEvent, EmailMessageChangeEvent, EmailServicesAddress, EmailServicesFunction, EmailTemplate, EmailTemplateChangeEvent, EngagementAttendeeChangeEvent, EngagementAttendeeHistory, EngagementChannelTypeHistory, EngagementChannelTypeShare, EngagementInteractionChangeEvent, EngagementInteractionHistory, EngagementInteractionShare, EngagementInterface, EngagementTopicChangeEvent, EngagementTopicHistory, EntitlementChangeEvent, EntitlementHistory, EntitlementTemplate, EntityMilestoneHistory, EntitySubscription, EventChangeEvent, EventRelationChangeEvent, EventRelayConfigChangeEvent, ExpressionSetHistory, ExpressionSetShare, ExpressionSetVersionHistory, ExternalEventMappingShare, FeedAttachment, FeedLike, FeedPollChoice, FeedPollVote, FeedSignal, FieldPermissions, FieldSecurityClassification, FiscalYearSettings, FlowInterviewLogShare, FlowInterviewShare, FlowOrchestrationEvent, FlowOrchestrationInstanceShare, FlowOrchestrationStageInstanceShare, FlowOrchestrationStepInstanceShare, FlowOrchestrationWorkItemShare, FlowRecordShare, FlowRecordVersionChangeEvent, FlowTestResultShare, Folder, Group, GroupMember, Holiday, IdeaComment, IdpEventLog, ImageHistory, ImageShare,

IncidentChangeEvent, IncidentHistory, IncidentRelatedItemChangeEvent, IncidentRelatedItemHistory, IncidentShare, IndividualChangeEvent, IndividualHistory, IndividualShare, KnowledgeableUser, LeadChangeEvent, LeadHistory, LeadShare, LeadStatus, LightningExitByPageMetrics, LightningToggleMetrics, LightningUsageByAppTypeMetrics, LightningUsageByBrowserMetrics, LightningUsageByFlexiPageMetrics, LightningUsageByPageMetrics, ListEmailChangeEvent, ListEmailShare, ListView, LocationChangeEvent, LocationHistory, LocationShare, LocationTrustMeasureShare, LoginHistory, LoginIp, MacroChangeEvent, MacroHistory, MacroInstructionChangeEvent, MacroShare, MacroUsageShare, ManagedContentVariantChangeEvent, MessagingEndUserHistory, MessagingEndUserShare, MessagingSessionHistory, MessagingSessionShare, MilestoneType, MLEngagementEvent, ObjectPermissions, OpportunityChangeEvent, OpportunityContactRoleChangeEvent, OpportunityFieldHistory, OpportunityLineItemChangeEvent, OpportunityShare, OpportunityStage, OrderChangeEvent, OrderHistory, OrderItemChangeEvent, OrderItemHistory, OrderShare, OrderStatus, Organization, OrgEmailAddressSecurity, OrgWideEmailAddress, OutgoingEmail, OutgoingEmailRelation, PackageLicense, PartnerRole, PartyConsentChangeEvent, PartyConsentHistory, PartyConsentShare, Period, PermissionSet, PermissionSetAssignment, PermissionSetTabSetting, Pricebook2ChangeEvent, Pricebook2History, PricebookEntryChangeEvent, PricebookEntryHistory, PrivacyJobSessionShare, PrivacyObjectSessionShare, PrivacyRTBFRequestHistory, PrivacyRTBFRequestShare, PrivacySessionRecordFailureShare, ProblemChangeEvent, ProblemHistory, ProblemIncidentChangeEvent, ProblemIncidentHistory, ProblemRelatedItemChangeEvent, ProblemRelatedItemHistory, ProblemShare, ProcessDefinition, ProcessExceptionEvent, ProcessExceptionShare, ProcessInstanceChangeEvent, ProcessInstanceStep, ProcessInstanceStepChangeEvent, ProcessNode, Product2ChangeEvent, Product2History, ProductEntitlementTemplate, Profile, ProfileSkillEndorsementHistory, ProfileSkillHistory, ProfileSkillShare, ProfileSkillUserHistory, PromptActionShare, PromptErrorShare, QueueSubject, QuickTextChangeEvent, QuickTextHistory, QuickTextShare, QuickTextUsageShare, RecentlyViewed, RecommendationChangeEvent, RecordActionHistory, RecordAlertHistory, RecordAlertShare, RecordType, ScorecardShare, SellerHistory, SellerShare, ServiceContractChangeEvent, ServiceContractHistory, ServiceContractShare, SetupAuditTrail, SetupEntityAccess, SharingRecordCollectionShare, Site, SiteHistory, SiteRedirectMapping, SocialPersonaHistory, SocialPostChangeEvent, SocialPostHistory, SocialPostShare, SolutionHistory, SolutionStatus, StaticResource, StreamingChannelShare, TableauHostMappingShare, TaskChangeEvent, TaskPriority, TaskStatus, ThreatDetectionFeedback, TimelineObjectDefinitionChangeEvent, TodayGoalShare, Topic, TopicUserEvent, Translation, User, UserAppMenuCustomizationShare, UserChangeEvent, UserDefinedLabelAssignmentShare, UserDefinedLabelShare, UserEmailPreferredPersonShare, UserLicense, UserLogin, UserPackageLicense, UserPreference, UserPrioritizedRecordShare, UserProvisioningRequestShare, UserRole, UserShare, VideoCallChangeEvent, VideoCallParticipantChangeEvent, VideoCallRecordingChangeEvent, VideoCallShare, VisualforceAccessMetrics,

```
VoiceCallChangeEvent, VoiceCallRecordingChangeEvent, VoiceCallShare, Vote,
WebLink, WorkAccessShare, WorkBadgeDefinitionHistory, WorkBadgeDefinitionShare,
WorkOrderChangeEvent, WorkOrderHistory, WorkOrderLineItemChangeEvent,
WorkOrderLineItemHistory, WorkOrderLineItemStatus, WorkOrderShare, WorkOrderStatus,
WorkPlanChangeEvent, WorkPlanHistory, WorkPlanShare, WorkPlanTemplateChangeEvent,
WorkPlanTemplateEntryChangeEvent, WorkPlanTemplateEntryHistory,
WorkPlanTemplateHistory, WorkPlanTemplateShare, WorkStepChangeEvent, WorkStepHistory,
WorkStepStatus, WorkStepTemplateChangeEvent, WorkStepTemplateHistory,
WorkStepTemplateShare, WorkThanksShare
```

Entités et champs non pris en charge pour ServiceNow

Les ServiceNow entités ou champs suivants ne sont pas pris en charge pour une utilisation dans le cadre d'une intégration zéro ETL avec une ServiceNow source.

```
ais_acl_overrides, ais_async_genius_result, ais_async_request, ais_connection,
ais_genius_result_configuration_parameters, ais_partition_health,
ais_partition_health_response, ais_publish_history, ais_relevancy_training_execution,
ais_relevancy_training_staging, ais_search_profile_relevancy_model,
catalog_draft_entities, clone_log, clone_log0000, clone_log0001, clone_log0002,
clone_log0003, clone_log0004, clone_log0005, clone_log0006, clone_log0007,
cmdb_ie_context, cmdb_ie_log, cmdb_ie_run, cmdb_ire_partial_payloads_index,
cmdb_qb_result_base$par1, cmdb$par1, discovery_log, discovery_log0000,
discovery_log0001, discovery_log0002, discovery_log0003, discovery_log0004,
discovery_log0005, discovery_log0006, discovery_log0007, ecc_agent_log,
entitlement_data, entl_subscription_map, gs_entitlement_plugin_mapping,
ih_transaction_exclusion, import_log, import_log0000, import_log0001, import_log0002,
import_log0003, import_log0004, import_log0005, import_log0006, import_log0007,
jrobin_archive, jrobin_database, jrobin_datasource, jrobin_definition, jrobin_graph,
jrobin_graph_line, jrobin_graph_set, jrobin_graph_set_member, jrobin_shard,
jrobin_shard_location, license_role_discovery_run, logger_configuration_validation,
m2m_analytics_event_logger, m2m_user_consent_info, ml_artifact_object_store,
np$sys_gen_ai_filter_sample, np$sys_ui_element, np$sys_ui_list_element,
one_api_service_plan_feature_invocation, one_api_service_plan_invocation,
open_nlu_predict_log, open_nlu_predict_log0000, open_nlu_predict_log0001,
open_nlu_predict_log0002, open_nlu_predict_log0003, open_nlu_predict_log0004,
open_nlu_predict_log0005, open_nlu_predict_log0006, open_nlu_predict_log0007,
pa_diagnostic_log, pa_diagnostic_log0000, pa_diagnostic_log0001,
pa_diagnostic_log0002, pa_diagnostic_log0003, pa_diagnostic_log0004,
pa_diagnostic_log0005, pa_diagnostic_log0006, pa_diagnostic_log0007, pa_favorites,
pa_job_log_rows, pa_job_log_rows0000, pa_job_log_rows0001, pa_job_log_rows0002,
pa_job_log_rows0003, pa_job_log_rows0004, pa_job_log_rows0005, pa_job_log_rows0006,
pa_job_log_rows0007, pa_migration_ignored_scores, pa_scores_l1, pa_scores_l2,
```

pa_scores_migration_groups, par_dashboard_conversion_backup, promin_log,
promin_log0000, promin_log0001, promin_log0002, promin_log0003, promin_log0004,
promin_log0005, promin_log0006, promin_log0007, promin_request_object,
proposed_change_verification_log, proposed_change_verification_log0000,
proposed_change_verification_log0001, proposed_change_verification_log0002,
proposed_change_verification_log0003, proposed_change_verification_log0004,
proposed_change_verification_log0005, proposed_change_verification_log0006,
proposed_change_verification_log0007, protected_table_log, protected_table_log0000,
protected_table_log0001, protected_table_log0002, protected_table_log0003,
protected_table_log0004, protected_table_log0005, protected_table_log0006,
protected_table_log0007, pwd_history, qb_query_results, scan_log,
scan_log0000, scan_log0001, scan_log0002, scan_log0003, scan_log0004,
scan_log0005, scan_log0006, scan_log0007, schema_validator_error,
sla_repair_log_entry, sla_repair_log_entry0000, sla_repair_log_entry0001,
sla_repair_log_entry0002, sla_repair_log_entry0003, sla_repair_log_entry0004,
sla_repair_log_entry0005, sla_repair_log_entry0006, sla_repair_log_entry0007,
sla_repair_log_message, sla_repair_log_message0000, sla_repair_log_message0001,
sla_repair_log_message0002, sla_repair_log_message0003, sla_repair_log_message0004,
sla_repair_log_message0005, sla_repair_log_message0006, sla_repair_log_message0007,
sn_bm_client_activity, sn_ci_analytics_st_actionable_notifs,
sn_ci_analytics_st_conv_completion_by_cat, sn_ci_analytics_st_conv_dynamic_property,
sn_ci_analytics_st_conversation, sn_ci_analytics_st_count_by_date,
sn_ci_analytics_st_event_occurrence, sn_ci_analytics_st_event_property_value_trend,
sn_ci_analytics_st_issue_auto_resolution, sn_ci_analytics_st_no_clicks,
sn_ci_analytics_st_no_results, sn_ci_analytics_st_property_summary_by_event,
sn_ci_analytics_st_session_count_per_locale, sn_ci_analytics_st_session_duration,
sn_ci_analytics_st_spokes_usage, sn_ci_analytics_st_topic_execution_stats,
sn_ci_analytics_st_topic_occurrence, sn_ci_analytics_st_trending_content,
sn_ci_analytics_st_trending_queries, sn_ci_analytics_st_users,
sn_cs_plugin_signatures, sn_cs_telemetry_log, sn_dfc_application, sn_dfc_product,
sn_employee_position, sn_entitlement_st_subscription_application_family,
sn_entitlement_st_subscription_application_users, sn_hr_sp_st_relevant_for_you,
sn_instance_clone_log, sn_instance_clone_log0000, sn_instance_clone_log0001,
sn_instance_clone_log0002, sn_instance_clone_log0003, sn_instance_clone_log0004,
sn_instance_clone_log0005, sn_instance_clone_log0006, sn_instance_clone_log0007,
sn_km_mr_st_kb_knowledge, sn_me_st_topic, sn_rf_conditional_definition,
sn_rf_evaluation_type, sn_rf_evaluation_type_input, sn_rf_recommendation_action,
sn_rf_recommendation_experience, sn_rf_recommendation_history,
sn_rf_recommendation_rule, sn_rf_record_display_configuration, sn_rf_trend_definition,
sn_sub_man_st_account_level_entitlement, sn_sub_man_st_gen_ai_metadata,
sn_sub_man_st_instance_used_assist_count, sn_sub_man_st_now_assist_creator_instances,
sn_sub_man_st_now_assists_aggregate, sn_sub_man_st_subscribed_groups,
sn_sub_man_st_subscription_insights, sn_sub_man_st_subscription_license_detail_metric,
sn_sub_man_st_unallocated_group_recommendation, sn_sub_man_st_unconfirmed_user_group,

sn_wn_user_app_activity, sn_wn_user_content_activity, snc_monitorable_item, snpar_sched_export_v_scheduled_export_visualization, spotlight, spotlight_audit, spotlight_copy_log_row, spotlight_copy_log_row0000, spotlight_copy_log_row0001, spotlight_copy_log_row0002, spotlight_copy_log_row0003, spotlight_copy_log_row0004, spotlight_copy_log_row0005, spotlight_copy_log_row0006, spotlight_copy_log_row0007, spotlight_job_log_row, spotlight_job_log_row0000, spotlight_job_log_row0001, spotlight_job_log_row0002, spotlight_job_log_row0003, spotlight_job_log_row0004, spotlight_job_log_row0005, spotlight_job_log_row0006, spotlight_job_log_row0007, st_dfc_performance_metric, st_license_detail_metric, st_on_call_hour, st_sc_wizard_question, st_sys_catalog_items_and_variable_sets, st_sys_design_system_icon, subscription_instance_stats, svc_container_config, svc_environment_config, svc_layer_config, svc_model_assoc_ci, svc_model_checkpoint_attr, svc_model_obj_cluster, svc_model_obj_constraint, svc_model_obj_deployable, svc_model_obj_element, svc_model_obj_impact, svc_model_obj_impactrule, svc_model_obj_package, svc_model_obj_path, svc_model_obj_relation, svc_model_obj_service, sys_administrative_script_transaction, sys_amb_message, sys_amb_processor, sys_analytics_batch_state, sys_analytics_config, sys_analytics_data_points_error, sys_analytics_event, sys_analytics_logger, sys_analytics_logger_field, sys_app_payload_loader_rule, sys_app_payload_unloader_rule, sys_app_scan_payload, sys_app_scan_variable, sys_app_scan_variable_type, sys_archive_destroy_log, sys_archive_destroy_run, sys_archive_log, sys_archive_run, sys_atf_transaction_log, sys_attachment_doc, sys_attachment_doc_v2, sys_attachment_soft_deleted, sys_audit, sys_audit_relation, sys_auth_policy_api_allowed, sys_aw_registered_scripting_modal, sys_cache_flush, sys_data_egress_source, sys_dm_delete_count, sys_export_set_log, sys_export_set_log0000, sys_export_set_log0001, sys_export_set_log0002, sys_export_set_log0003, sys_export_set_log0004, sys_export_set_log0005, sys_export_set_log0006, sys_export_set_log0007, sys_flow_compiled_flow, sys_flow_compiled_flow_chunk, sys_flow_context_chunk, sys_flow_context_chunk_archive, sys_flow_context_inputs_chunk, sys_flow_execution_history, sys_flow_log, sys_flow_log0000, sys_flow_log0001, sys_flow_log0002, sys_flow_log0003, sys_flow_plan_context_binding, sys_flow_report_doc, sys_flow_report_doc_chunk, sys_flow_report_doc_chunk_archive, sys_flow_runtime_state_chunk, sys_flow_runtime_value_chunk, sys_flow_subflow_plan_chunk, sys_flow_trigger_plan_chunk, sys_flow_val_listener, sys_flow_value, sys_flow_value_chunk, sys_gen_ai_config_example, sys_gen_ai_feature_mapping, sys_gen_ai_strategy_mapping, sys_gen_ai_usage_log, sys_generative_ai_capability_definition, sys_generative_ai_log, sys_generative_ai_response_validator, sys_generative_ai_validator, sys_geo_routing, sys_geo_routing_config, sys_hop_token, sys_hub_action_plan_chunk, sys_hub_snapshot_chunk, sys_journal_field, sys_journal_field_edit, sys_json_chunk, sys_kaa_policy, sys_kaa_subidentity_assertion, sys_kaa_user_policy_mapping, sys_mapapplication, sys_mass_encryption_job, sys_notification_execution_log, sys_notification_execution_log0000, sys_notification_execution_log0001,

```

sys_notification_execution_log0002, sys_notification_execution_log0003,
sys_notification_execution_log0004, sys_notification_execution_log0005,
sys_notification_execution_log0006, sys_notification_execution_log0007,
sys_nowmq_message, sys_nowmq_provider_param_definition, sys_orchestrator_action,
sys_pd_asset_configuration, sys_pd_context_chunk, sys_pd_context_log,
sys_pd_snapshot_chunk, sys_pd_trigger_license, sys_processing_framework_job,
sys_query_index_hint, sys_query_rewrite, sys_query_string_log,
sys_replication_queue, sys_replication_queue0, sys_replication_queue1,
sys_replication_queue2, sys_replication_queue3, sys_replication_queue4,
sys_replication_queue5, sys_replication_queue6, sys_replication_queue7,
sys_request_performance, sys_rollback_blacklisted, sys_rollback_conflict,
sys_rollback_incremental, sys_rollback_log, sys_rollback_log0000,
sys_rollback_log0001, sys_rollback_log0002, sys_rollback_log0003,
sys_rollback_log0004, sys_rollback_log0005, sys_rollback_log0006,
sys_rollback_log0007, sys_rollback_run, sys_rollback_schema_change,
sys_rollback_schema_conflict, sys_rollback_sequence, sys_scheduler_assignment,
sys_scheduler_memory_pressure_job_log, sys_script_adapter_rule,
sys_script_batch_adapter_rule, sys_search_source_filter, sys_service_authentication,
sys_signing_job, sys_suggestion_reader, sys_sync_history_review, sys_trend,
sys_unreferenced_preview, sys_unreferenced_record_rule, sys_upgrade_manifest,
sys_upgrade_state, sys_ux_asset_cache_buster, sys_ux_lib_component_prop,
sys_ux_lib_presource, sys_ux_page_action, sys_ux_page_action_binding,
sys_sevent_queue_runtime, syslog, syslog_app_scope0000, syslog_app_scope0001,
syslog_app_scope0002, syslog_app_scope0003, syslog_app_scope0004,
syslog_app_scope0005, syslog_app_scope0006, syslog_app_scope0007, syslog_email0000,
syslog_email0001, syslog_email0002, syslog_email0003, syslog_email0004,
syslog_email0005, syslog_email0006, syslog_email0007, syslog_transaction,
syslog_transaction0000, syslog_transaction0001, syslog_transaction0002,
syslog_transaction0003, syslog_transaction0004, syslog_transaction0005,
syslog_transaction0006, syslog_transaction0007, syslog0000, syslog0001, syslog0002,
syslog0003, syslog0004, syslog0005, syslog0006, syslog0007, ts_attachment,
ts_c_1_0, ts_c_1_1, ts_c_1_2, ts_c_1_3, ts_c_1_4, ts_c_1_5, ts_c_1_6, ts_c_1_7,
ts_c_1_8, ts_c_1_9, ts_c_10_0, ts_c_10_1, ts_c_10_2, ts_c_10_3, ts_c_10_4,
ts_c_10_5, ts_c_10_6, ts_c_10_7, ts_c_10_8, ts_c_10_9, ts_c_11_0, ts_c_11_1,
ts_c_11_2, ts_c_11_3, ts_c_11_4, ts_c_11_5, ts_c_11_6, ts_c_11_7, ts_c_11_8,
ts_c_11_9, ts_c_2_0, ts_c_2_1, ts_c_2_2, ts_c_2_3, ts_c_2_4, ts_c_2_5, ts_c_2_6,
ts_c_2_7, ts_c_2_8, ts_c_2_9, ts_c_3_0, ts_c_3_1, ts_c_3_2, ts_c_3_3, ts_c_3_4,
ts_c_3_5, ts_c_3_6, ts_c_3_7, ts_c_3_8, ts_c_3_9, ts_c_39_0, ts_c_39_1, ts_c_39_2,
ts_c_39_3, ts_c_39_4, ts_c_39_5, ts_c_39_6, ts_c_39_7, ts_c_39_8, ts_c_39_9,
ts_c_40_0, ts_c_40_1, ts_c_40_2, ts_c_40_3, ts_c_40_4, ts_c_40_5, ts_c_40_6,
ts_c_40_7, ts_c_40_8, ts_c_40_9, ts_c_41_0, ts_c_41_1, ts_c_41_2, ts_c_41_3,
ts_c_41_4, ts_c_41_5, ts_c_41_6, ts_c_41_7, ts_c_41_8, ts_c_41_9, ts_c_42_0,
ts_c_42_1, ts_c_42_2, ts_c_42_3, ts_c_42_4, ts_c_42_5, ts_c_42_6, ts_c_42_7,
ts_c_42_8, ts_c_42_9, ts_c_43_0, ts_c_43_1, ts_c_43_2, ts_c_43_3, ts_c_43_4,

```

ts_c_43_5, ts_c_43_6, ts_c_43_7, ts_c_43_8, ts_c_43_9, ts_c_44_0, ts_c_44_1, ts_c_44_2, ts_c_44_3, ts_c_44_4, ts_c_44_5, ts_c_44_6, ts_c_44_7, ts_c_44_8, ts_c_44_9, ts_c_45_0, ts_c_45_1, ts_c_45_2, ts_c_45_3, ts_c_45_4, ts_c_45_5, ts_c_45_6, ts_c_45_7, ts_c_45_8, ts_c_45_9, ts_c_6_0, ts_c_6_1, ts_c_6_2, ts_c_6_3, ts_c_6_4, ts_c_6_5, ts_c_6_6, ts_c_6_7, ts_c_6_8, ts_c_6_9, ts_c_7_0, ts_c_7_1, ts_c_7_2, ts_c_7_3, ts_c_7_4, ts_c_7_5, ts_c_7_6, ts_c_7_7, ts_c_7_8, ts_c_7_9, ts_c_8_0, ts_c_8_1, ts_c_8_2, ts_c_8_3, ts_c_8_4, ts_c_8_5, ts_c_8_6, ts_c_8_7, ts_c_8_8, ts_c_8_9, ts_c_attachment, ts_chain, ts_deleted_doc, ts_document, ts_field, ts_index_stats, ts_phrase, ts_search_stats, ts_v4_attachment, ts_word, ua_app_metadata, ua_audit_stats, ua_extra_page, ua_monitor_property, ua_monitor_property_audit, ua_shared_service, ua_sn_table_inventory, ua_sp_known_bot, ua_upload_log, v_ais_result_improvement_rule_condition_builder_values, v_cluster_nodes, v_cxs_search_resource, v_db_index, v_db_trigger, v_file_load_order, v_interaction_context, v_iostats, v_mysql_proclist, v_mysql_status, v_mysql_variables, v_on_call_report_cache, v_pa_par_combined_dashboard, v_pd_activity_condition_to_run, v_pd_activity_start_rule_with_condition, v_pd_lane_condition_to_run, v_sql_debug, v_st_kb_category, v_st_kb_most_viewed, v_st_kb_recently_viewed, v_st_km_genai_mra_similar_task, v_st_popular_item, v_st_recent_item, v_st_sc_cat_item, v_st_sc_catalog, v_st_sc_category, validator_run_summary, vtb_card_history, wf_log, wf_log0000, wf_log0001, wf_log0002, wf_log0003, wf_log0004, wf_log0005, wf_log0006, wf_log0007, spotlight_criteria, pa_snapshots, pa_widget_indicators, pa_widgets, sn_cim_register, global, gsw_change_log, gsw_content, gsw_content_group, gsw_content_information, gsw_status_of_content, multi_factor_browser_fingerprint, multi_factor_criteria, pa_filters, password_policy, plan_execution, plan_mysql, plan_oracle, plan_postgres, sc_rest_api_without_access_policy, sn_actsub_activity, sn_actsub_activity_fanout, sn_actsub_activity_stream, sn_actsub_activity_type, sn_actsub_atype_attributes, sn_actsub_atype_notif_pref, sn_actsub_module, sn_actsub_notif_object, sn_actsub_subobject_stream, sn_actsub_subscribable_object, sn_actsub_subscription_notif_pref, sn_actsub_user_stream, sn_appclient_store_outbound_http_quota, sn_appcreator_app_template, sn_critical_update, sn_docker_spoke_images, sn_employee_app, sn_employee_app_access, sn_employee_app_access_criteria, sn_entitlement_genai_assist_counts, sn_entitlement_genai_creator_user_counts, sn_entitlement_genai_creator_users, sn_mif_instance, sn_mif_sync_data, sn_mif_sync_status, sn_mif_table_registration, sn_mif_trust_config, sn_vsc_best_practice_configurations, sn_vsc_best_practice_goals, sn_vsc_changed_hardening_settings, sn_vsc_changed_scan_findings, sn_vsc_check_security_area, sn_vsc_elevation_event, sn_vsc_event, sn_vsc_export_event, sn_vsc_export_setting, sn_vsc_harc_compliance_status_lookup, sn_vsc_hardening_compliance_scores, sn_vsc_impersonation_event, sn_vsc_instance_hardening_settings, sn_vsc_login_event, sn_vsc_scan_comparisons, sn_vsc_scan_summary, sn_vsc_security_check_categories, sn_vsc_security_check_configurations, sn_vsc_security_configuration_groups, sn_vsc_security_privacy_capabilities, sn_vsc_updated_settings,


```
sn_vsc_user_comparisons, sys_app_hash_inventory, sys_coalesce_strategy_deferred,
sys_flow_secure_data, sys_formula_function, sys_geocoding_request,
sys_global_file_hash, sys_import_set_row, sys_index, sys_index_explain,
sys_installation_schedule, sys_installation_schedule_item, sys_offline_app,
sys_package, sys_package_dependency_item, sys_package_dependency_m2m,
sys_plugins, sys_querystat, sys_reap_package, sys_scoped_plugin,
sys_stage_storage_alias, sys_storage_alias, sys_storage_table_alias, sys_store_app,
sys_table_partition, sys_upgrade_history_log, sys_user_public_credential,
sys_webauthn_authentication_request, sys_webauthn_registration_request,
syslog_app_scope, syslog_email, syslog_page_timing, ua_instance_state_config,
v_expression_cache, v_private_cache, v_shared_cache, sys_amb_message0002,
sys_amb_message0004, sys_amb_message0005, sys_metadata, v_par_unified_report_viz
```

Configuration d'une cible d'intégration zéro ETL

Plusieurs options sont proposées AWS lors de la configuration d'une cible pour une intégration zéro ETL. La cible peut être un entrepôt de Amazon Redshift données crypté ou un catalogue Amazon SageMaker Lakehouse.

Avant de sélectionner la cible pour l'intégration zéro ETL, vous devez configurer l'une des ressources cibles suivantes.

Les options de configuration pour une cible dans une intégration zéro ETL sont les suivantes :

- Catalogue et base de données Amazon SageMaker Lakehouse configurés avec le stockage Amazon S3 standard. Consultez [Configuration d'un catalogue Amazon SageMaker Lakehouse avec un stockage S3 standard](#).
- Un catalogue Amazon SageMaker Lakehouse configuré avec le bucket Amazon S3 Tables. Consultez [Configuration des tables Amazon S3 en tant que cible](#).
- Un catalogue Amazon SageMaker Lakehouse configuré avec le stockage géré par Amazon Redshift. Consultez [Configuration d'un catalogue Amazon SageMaker Lakehouse avec stockage géré Amazon Redshift](#).
- Un entrepôt de données Amazon Redshift identifié par un espace de noms Redshift. Consultez [Configuration d'une cible d'entrepôt de Amazon Redshift données](#).

Note

Vous ne pouvez pas modifier la cible d'une intégration zéro ETL après sa création.

Configuration d'un catalogue Amazon SageMaker Lakehouse avec un stockage S3 standard

Cette section décrit les conditions préalables et les étapes de configuration pour configurer un compartiment Amazon S3 normal comme espace de stockage pour la cible de votre catalogue Amazon SageMaker Lakehouse dans le cadre d'une intégration zéro ETL.

Conditions préalables à la mise en place d'une intégration

Avant de créer une intégration zéro ETL avec un catalogue Amazon SageMaker Lakehouse à l'aide d'un stockage S3 standard, vous devez effectuer les tâches de configuration suivantes :

1. Configuration d'une AWS Glue base de données
2. Fournir une politique RBAC du catalogue
3. Créer un rôle IAM cible

Après avoir configuré le catalogue Amazon SageMaker Lakehouse avec le stockage Amazon S3 standard, vous pouvez terminer la configuration [Configuration de l'intégration avec votre cible](#) de l'intégration.

Configuration des tables Amazon S3 en tant que cible

Cette section décrit les conditions préalables et les étapes de configuration pour configurer les tables Amazon S3 en tant que cible pour votre intégration zéro ETL.

Conditions préalables à la mise en place d'une intégration

Avant de créer une intégration zéro ETL avec Amazon S3 Tables comme cible, vous devez effectuer les tâches de configuration suivantes :

1. Configuration du compartiment de tables Amazon S3
2. Fournir une politique RBAC du catalogue
3. Créer un rôle IAM cible

Configuration du compartiment de tables Amazon S3

1. Créez un compartiment de tables S3 dans votre compte en suivant les instructions de la section [Getting started with Amazon S3 Tables](#).

2. Activez les intégrations Analytics avec votre bucket S3-Table en suivant ces instructions :

[Intégration des AWS services avec Amazon S3 Tables.](#)

Fournir une politique RBAC du catalogue

Les autorisations suivantes doivent être ajoutées à la politique RBAC du catalogue pour permettre les intégrations entre la source et la cible du catalogue des tables Amazon S3.

La politique de ressources du AWS Glue catalogue cible doit inclure les autorisations du service Glue pour `AuthorizeInboundIntegration`. En outre, une `CreateInboundIntegration` autorisation est requise soit sur le principal source qui crée l'intégration, soit dans la politique de AWS Glue ressource cible.

Note

Dans le cas d'un scénario entre comptes, la politique de ressources du catalogue principal et celle du AWS Glue catalogue cible doivent inclure des `CreateInboundIntegration` autorisations « glue : » sur la ressource.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      // Optional for same account but mandatory for cross account scenarios
      // Allow Alice to create Integration on Target Catalog
      "Principal": {
        "AWS": [
          "arn:aws:iam::<source-account-id>:user/Alice"
        ]
      },
      "Effect": "Allow",
      "Action": [
        "glue:CreateInboundIntegration"
      ],
      "Resource": [
        "arn:aws:glue:<region>:<Target-Account-Id>:catalog/<s3tablescatalog>/*"
      ],
      "Condition": {
        "StringLike": {
          "aws:SourceArn": "arn:aws:dynamodb:<region>:<Account>:table/<table-name>"
        }
      }
    }
  ]
}
```

```

    }
  },
  { // Required: Allow Glue to Authorize the Inbound Integration on behalf of Bob
    "Principal": {
      "Service": [
        "glue.amazonaws.com"
      ]
    },
    "Effect": "Allow",
    "Action": [
      "glue:AuthorizeInboundIntegration"
    ],
    "Resource": [
      "arn:aws:glue:<region>:<Target-Account-Id>:catalog/<s3tablescatalog>/*"
    ],
    "Condition": {
      "StringEquals": {
        "aws:SourceArn": "arn:aws:dynamodb:<region>:<account-id>:table/<table-name>"
      }
    }
  }
]
}

```

Note

<s3tablescatalog>Remplacez-le par le nom du catalogue de vos tables S3.

Créer un rôle IAM cible

Créez un rôle IAM cible avec les autorisations et les relations de confiance suivantes :

Exemple de politique IAM :

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Action": [
        "s3tables:ListTableBuckets",
        "s3tables:GetTableBucket",
        "s3tables:GetTableBucketEncryption",

```

```

        "s3tables:GetNamespace",
        "s3tables:CreateNamespace",
        "s3tables:ListNamespaces",
        "s3tables:CreateTable",
        "s3tables:GetTable",
        "s3tables:GetTableEncryption",
        "s3tables:ListTables",
        "s3tables:GetTableMetadataLocation",
        "s3tables:UpdateTableMetadataLocation",
        "s3tables:GetTableData",
        "s3tables:PutTableData"
    ],
    "Resource": "arn:aws:s3tables:<region>:<account-id>:bucket/*",
    "Effect": "Allow"
},
{
    "Action": [
        "cloudwatch:PutMetricData"
    ],
    "Resource": "*",
    "Condition": {
        "StringEquals": {
            "cloudwatch:namespace": "AWS/Glue/ZeroETL"
        }
    },
    "Effect": "Allow"
},
{
    "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
    ],
    "Resource": "*",
    "Effect": "Allow"
}
]
}

```

Ajoutez la politique de confiance suivante dans le rôle Target IAM pour permettre au AWS Glue Service de l'assumer :

```
{
```

```
"Version": "2012-10-17",
"Statement": [
  {
    "Effect": "Allow",
    "Principal": {
      "Service": "glue.amazonaws.com"
    },
    "Action": "sts:AssumeRole"
  }
]
```

Note

Assurez-vous qu'il n'existe aucune instruction DENY explicite pour ce rôle IAM cible dans la politique de ressources du bucket S3-Tables. Un DENY explicite remplacerait toutes les autorisations ALLOW et empêcherait l'intégration de fonctionner correctement.

Configuration d'un catalogue Amazon SageMaker Lakehouse avec stockage géré Amazon Redshift

Cette section décrit les conditions préalables et les étapes de configuration pour configurer un catalogue Amazon SageMaker Lakehouse avec un stockage Amazon Redshift géré (RMS) comme cible pour votre intégration zéro ETL.

Conditions préalables à la mise en place d'une intégration

Avant de créer une intégration zéro ETL avec un catalogue Amazon SageMaker Lakehouse à l'aide du stockage géré Redshift, vous devez effectuer les tâches de configuration suivantes :

1. Configuration d'un Amazon Redshift cluster ou d'un groupe de travail sans serveur
2. Enregistrez l' Amazon Redshift intégration avec Lake Formation
3. Création d'un catalogue géré dans Lake Formation
4. Configuration des autorisations IAM

Configuration du stockage Amazon Redshift géré

Pour configurer le stockage Amazon Redshift géré pour votre intégration Zero-ETL :

1. Créez ou utilisez un cluster Amazon Redshift ou un groupe de travail sans serveur existant. Assurez-vous que le `enable_case_sensitive_identifier` paramètre est activé dans le Amazon Redshift groupe de travail ou le cluster cible pour que l'intégration soit réussie. Pour plus d'informations sur l'activation de la distinction majuscules/minuscules, consultez la section [Activer la distinction majuscules/minuscules pour votre entrepôt de données](#) dans le guide de gestion Amazon Redshift.
2. Enregistrez une intégration de Redshift dans le catalogue dans. AWS Lake Formation Consultez la section [Enregistrement de Amazon Redshift clusters et d'espaces de noms dans le catalogue de AWS Glue données](#).
3. Créez un catalogue fédéré ou géré dans. AWS Lake Formation Pour plus d'informations, consultez :
 - [Intégrer Amazon Redshift des données dans le catalogue AWS Glue de données](#)
 - [Création d'un catalogue Amazon Redshift géré dans le catalogue AWS Glue de données](#)
4. Configurez les autorisations IAM pour le rôle cible. Le rôle a besoin d'autorisations pour accéder aux ressources Redshift et Lake Formation. Au minimum, le rôle doit avoir :
 - Autorisations d'accès au cluster ou au groupe de travail Redshift
 - Autorisations d'accès au catalogue Lake Formation
 - Autorisations pour créer et gérer des tables dans le catalogue
 - CloudWatch et CloudWatch enregistre les autorisations à des fins de surveillance

Après avoir configuré le catalogue Amazon SageMaker Lakehouse avec le stockage géré par Amazon Redshift, vous pouvez terminer la configuration [Configuration de l'intégration avec votre cible](#) de l'intégration.

Configuration d'une cible d'entrepôt de Amazon Redshift données

Cette section décrit les conditions préalables et les étapes de configuration pour configurer un entrepôt de Amazon Redshift données comme cible pour votre intégration zéro ETL.

Conditions préalables à la mise en place d'une intégration

Avant de créer une intégration zéro ETL avec une cible d'entrepôt de Amazon Redshift données, vous devez effectuer les tâches de configuration suivantes :

1. Configuration d'un Amazon Redshift cluster ou d'un groupe de travail sans serveur
2. Configuration de la distinction majuscules

3. Configuration des autorisations IAM

Configuration de l'entrepôt Amazon Redshift de données

Pour configurer un entrepôt de Amazon Redshift données pour votre intégration Zero-ETL :

1. Accédez à la [Amazon Redshift console](#) et cliquez sur Créer un cluster ou utilisez un cluster existant. Pour Amazon Redshift Serverless, cliquez sur Créer un groupe de travail.
2. Si vous créez un nouveau cluster, choisissez une taille de cluster appropriée et assurez-vous que votre cluster est crypté. Pour Serverless, configurez les paramètres du groupe de travail en fonction de vos besoins.
3. Assurez-vous que le `enable_case_sensitive_identification` paramètre est activé dans le Amazon Redshift groupe de travail ou le cluster cible pour que l'intégration soit réussie. Pour plus d'informations sur l'activation de la distinction majuscules/minuscules, consultez la section [Activer la distinction majuscules/minuscules pour votre entrepôt de données](#) dans le guide de gestion Amazon Redshift.
4. Configurez les autorisations IAM pour permettre à l'intégration Zero-ETL d'accéder à votre entrepôt de Amazon Redshift données. Vous devez créer un rôle IAM avec les autorisations suivantes :
 - Autorisations d'accès au Amazon Redshift cluster ou au groupe de travail
 - Autorisations permettant de créer et de gérer des bases de données et des tables dans Amazon Redshift
 - CloudWatch et Amazon CloudWatch enregistre les autorisations à des fins de surveillance
5. Une fois la configuration du Amazon Redshift groupe de travail ou du cluster terminée, vous devez configurer votre entrepôt de données pour les intégrations sans ETL. Consultez [Getting started with zero-ETL integrations](#) dans le guide de gestion Amazon Redshift pour plus d'informations.

Note

Lorsque vous utilisez un entrepôt de Amazon Redshift données comme cible, l'intégration crée un schéma dans la base de données spécifiée pour stocker les données répliquées. Le nom du schéma est dérivé du nom de l'intégration.

Après avoir configuré l'entrepôt de Amazon Redshift données, vous pouvez [Configuration de l'intégration avec votre cible](#) terminer la configuration de l'intégration.

Configuration de l'intégration avec votre cible

Après avoir configuré vos ressources cibles, sélectionné votre connexion et spécifié un rôle IAM source, procédez comme suit pour terminer la configuration de l'intégration :

1. Spécifiez la cible que vous avez configurée lors des étapes précédentes.
2. Sélectionnez l'option AWS Glue Corriger le problème pour moi. Pour la Amazon Redshift cible, cela permettra de :
 - Appliquez un principal de service autorisé sur le Amazon Redshift cluster ou le groupe de travail sans serveur.
 - Appliquez un ARN AWS Glue source autorisé au Amazon Redshift cluster ou au groupe de travail sans serveur.
 - Associez un nouveau groupe de paramètres à `enable_case_sensitive_identifier = true`.

Target details
Target type
 Transactional Data Lake
Namespace or Catalog
Choose an Amazon Redshift namespace or AWS Glue Catalog
redshift-cluster-1008  [View](#) [Create new namespace](#)
Note: the target of a zero-ETL integration cannot be modified after creation

 **Fix resource policy and case sensitivity parameter**
The selected target does not have the correct resource policy and case sensitivity parameter to support a zero-ETL integration. You can have AWS Glue fix this for you, or you can manually update them in the Redshift console.
☒ **Fix it for me**
AWS Glue will fix this by adding the current account and the selected source in the resource policy and enabling case sensitivity. A reboot may be required.

3. Indiquez le nom de l'intégration et choisissez Create and launch Integration.
4. Une fois que votre intégration est active, accédez à la page des détails de l'intégration et choisissez Créer une base de données à partir de l'intégration.
5. Enfin, vous pouvez accéder à l'éditeur de requêtes Redshift et vous connecter à votre base de données pour valider l'instantané et les données incrémentielles.

Note

Vous ne pouvez utiliser que des caractères alphanumériques minuscules et des traits de soulignement dans l'espace de noms ou le nom du catalogue. Cela est différent de ce que

permet le catalogue de AWS Glue données pour créer une base de données avec n'importe quel nom (y compris les caractères spéciaux).

Spécification des partitions et guide de dénidification des schémas

Lorsque vous travaillez avec des sources de données NoSQL telles que DynamoDB et des applications SaaS, les données présentent souvent des défis uniques en matière d'analyse :

1. Les enregistrements d'une même table peuvent avoir un schéma différent
2. Les enregistrements imbriqués au sein d'une même table peuvent être représentés différemment
3. Les structures imbriquées complexes telles que les cartes et les tableaux nécessitent une transformation pour des requêtes efficaces
4. Une organisation optimale des données est nécessaire pour garantir les performances des requêtes à grande échelle

AWS Les intégrations Glue Zero-ETL répondent à ces défis grâce à deux puissantes fonctionnalités :

- Désimbrication du schéma : aplatit automatiquement les structures de données imbriquées complexes dans des formats adaptés à l'analyse, avec des niveaux de désimbrication configurables pour trouver un équilibre entre la préservation de la structure des données et l'optimisation pour la simplicité des requêtes.
- Partitionnement des données : organise les données en partitions logiques en fonction de colonnes spécifiées ou de dimensions temporelles, améliorant ainsi les performances des requêtes et réduisant les coûts en permettant l'élagage des partitions lors de l'exécution des requêtes.

Afin d'interroger efficacement ces sources de données, AWS Glue Zero-ETL fournit des out-of-the-box schémas de gestion et de partitionnement pour les données sources répliquées dans la base de données Glue AWS cible. Vous pouvez configurer les paramètres de désimbrication et de partitionnement du schéma pour chaque table via l' `CreateIntegrationTableProperty` API, ce qui permet de contrôler avec précision la manière dont les données sont structurées et organisées pour les charges de travail d'analyse.

Comportement de dénidification et de partitionnement par défaut

1. AWS Glue Zero-ETL prend par défaut la valeur FULL Unnest lorsqu'aucune option de désimbrication n'est fournie pour la table cible
2. AWS Glue Zero-ETL utilise par défaut le partitionnement par bucket lorsque aucun élément n'est fourni pour la PartitionSpec table cible

Désimbrication du schéma

Lors de l'intégration à des services d'analyse via Zero-ETL, vous pouvez choisir la manière dont les structures imbriquées sont représentées dans les tables cibles. AWS Glue Zero-ETL propose des options de désimbrication des schémas pour aplatir les structures de données complexes dans des formats plus adaptés aux analyses.

Options de dénidification

Lorsque vous créez une intégration zéro ETL avec une source, vous pouvez choisir l'une des options de dénidification suivantes. Ces options correspondent à des valeurs d'énumération spécifiques que vous utiliserez lors de l'appel de l' `CreateIntegrationTableProperty` API.

Aucune désimbrication (par défaut)

Valeur de l'API : **NO_UNNEST**

Préserve la structure imbriquée d'origine des éléments DynamoDB. Les cartes et les listes sont stockées sous forme de colonnes structurées dans la cible.

Idéal pour : préserver la structure exacte de vos données DynamoDB lorsque vos outils d'analyse peuvent fonctionner avec des données imbriquées.

Démanteler un niveau

Valeur de l'API : **TOP_LEVEL**

Aplatit le niveau supérieur des cartes imbriquées en colonnes individuelles. Les structures de listes restent imbriquées.

Idéal pour : trouver un équilibre entre la préservation de la structure des données et la simplicité des requêtes lorsque vos éléments DynamoDB ont un schéma cohérent.

Démantelez tous les niveaux

Valeur de l'API : **FULL**

Aplatit de manière récursive toutes les structures imbriquées (cartes et listes) en colonnes individuelles avec notation par points pour les nommer.

Idéal pour : optimiser la simplicité des requêtes lorsque vous travaillez avec des structures profondément imbriquées et des outils d'analyse privilégiant les schémas plats.

Note

Une désimbrication complète peut donner lieu à des tables très larges comportant de nombreuses colonnes si vos données DynamoDB présentent des structures variables ou profondément imbriquées.

Exemple Utilisation des options de dénidification dans l'API

Lors de la configuration de la désimbrication du schéma via l' `CreateIntegrationTableProperty` API, spécifiez l'option de désimbrication dans le paramètre : `UnnestSpec`

```
aws glue create-integration-table-property \  
  --resource-arn "arn:aws:glue:us-east-1:123456789012:integration/my-integration" \  
  --table-name "my-table" \  
  --table-properties '{  
    "unnestSpec": "FULL"  
  }'
```

Exemples de dénidification

Prenons l'exemple d'un élément DynamoDB dont la structure est la suivante :

```
{  
  "ProductId": "P12345",  
  "ProductDetails": {  
    "Name": "Smartphone",  
    "Brand": "TechCo",  
    "Specifications": {  
      "Color": "Black",
```

```
    "Storage": "128GB"
  },
  "Reviews": [
    {
      "Rating": 5,
      "Comment": "Great product!"
    },
    {
      "Rating": 4,
      "Comment": "Good value."
    }
  ]
}
```

Aucun exemple de dénidification

En l'absence de dénidification, la table cible comporterait des colonnes :

- ProductId (chaîne)
- ProductDetails (structure)
- Examens (ensemble de structures)

Les requêtes devraient utiliser des modèles d'accès aux structures et aux tableaux :

```
SELECT
  ProductId,
  ProductDetails.Name,
  ProductDetails.Specifications.Color
FROM product_table;
```

Exemple de Unnest à un niveau

Avec un niveau d'inimbrication, la table cible comporterait des colonnes :

- ProductId (chaîne)
- ProductDetails_Nom (chaîne)
- ProductDetails_Brand (chaîne)
- ProductDetails_Spécifications (structure)

- Examens (ensemble de structures)

Les requêtes seraient simplifiées pour le premier niveau :

```
SELECT
  ProductId,
  ProductDetails_Name,
  ProductDetails_Specifications.Color
FROM product_table;
```

Exemple de désintégration de tous les niveaux

Une fois tous les niveaux non imbriqués, la table cible comporterait des colonnes et des valeurs :

Nom de colonne (type)	Valeur
ProductId (chaîne)	P12345
ProductDetails_Nom (chaîne)	Smartphone
ProductDetails_Brand (chaîne)	TechCo
ProductDetails_Specifications_Color (chaîne)	Black
ProductDetails_Specifications_Storage (chaîne)	128 GO
Reviews_0_Rating (nombre)	5
Reviews_0_Comment (chaîne)	Excellent produit !
Reviews_1_Rating (nombre)	4
Reviews_1_Comment (chaîne)	Bon rapport qualité/prix

Les requêtes seraient entièrement aplaties :

```
SELECT
  ProductId,
  ProductDetails_Name,
  ProductDetails_Specifications_Color
```

```
FROM product_table;
```

Partitionnement des données pour les intégrations sans ETL

Qu'est-ce que le partitionnement des données ?

Le partitionnement des données est une technique qui divise les grands ensembles de données en segments plus petits et plus faciles à gérer appelés partitions. Dans le contexte des intégrations de AWS Glue Zero-ETL, le partitionnement organise vos données dans l'emplacement cible en fonction de valeurs de colonne spécifiques ou de transformations de ces valeurs.

Avantages du partitionnement des données

Le partitionnement efficace des données présente plusieurs avantages essentiels pour les charges de travail analytiques :

- Performances de requêtes améliorées : les requêtes peuvent ignorer les partitions non pertinentes (élagage des partitions), réduisant ainsi la quantité de données à analyser.
- Coûts réduits : en scannant moins de données, vous pouvez réduire le calcul et I/O les coûts liés à vos requêtes d'analyse.
- Meilleure évolutivité : le partitionnement permet le traitement parallèle des segments de données, permettant ainsi une mise à l'échelle plus efficace des charges de travail analytiques.
- Gestion simplifiée du cycle de vie des données : vous pouvez gérer les politiques de conservation au niveau de la partition, ce qui facilite l'archivage ou la suppression des anciennes données.

Principaux concepts de partitionnement

Colonnes de partition

Colonnes de vos données utilisées pour déterminer la manière dont les enregistrements sont organisés en partitions. Les colonnes de partition efficaces doivent s'aligner sur les modèles de requêtes courants et avoir une cardinalité appropriée.

Fonctions de partition

Transformations appliquées aux valeurs des colonnes de partition pour créer les limites réelles de la partition. Les exemples incluent l'identité (en utilisant la valeur brute), les fonctions basées sur le temps (année, mois, jour, heure) et le découpage en compartiments.

Élagage de cloisons

Processus par lequel le moteur de requête identifie et ignore les partitions qui ne contiennent pas de données pertinentes pour une requête, ce qui améliore considérablement les performances.

Granularité de partition

Niveau de détail auquel les données sont partitionnées. Une granularité plus fine (davantage de partitions) peut améliorer les performances des requêtes, mais peut augmenter la surcharge de métadonnées. Une granularité plus grossière (moins de partitions) réduit la surcharge de métadonnées, mais peut entraîner l'analyse d'un plus grand nombre de données que nécessaire.

Partitionnement dans les intégrations AWS Glue Zero-ETL

AWS Les intégrations Glue Zero-ETL utilisent le format de table Apache Iceberg, qui fournit des fonctionnalités de partitionnement avancées. Lorsque vous créez une intégration zéro ETL, vous pouvez :

- Utilisez des stratégies de partitionnement par défaut optimisées pour votre source de données
- Définissez des spécifications de partitionnement personnalisées adaptées à vos modèles de requêtes
- Appliquez des transformations aux colonnes de partition (particulièrement utile pour le partitionnement basé sur l'horodatage)
- Combinez plusieurs stratégies de partition pour un partitionnement à plusieurs niveaux

Les configurations de partitionnement sont spécifiées via l'`CreateIntegrationTablePropertyAPI` lors de la configuration de votre intégration Zero-ETL. Une fois configuré, AWS Glue applique automatiquement ces stratégies de partitionnement pour organiser vos données dans l'emplacement cible.

Référence de l'API de spécification des partitions

Utilisez les paramètres suivants dans l' `CreateIntegrationTableProperties` API pour configurer le partitionnement :

PartitionSpec

Tableau de spécifications de partition qui définit la manière dont les données sont partitionnées dans l'emplacement cible.


```
{
  "partitionSpec": [
    {
      "fieldName": "timestamp_col",
      "functionSpec": "month",
      "conversionSpec": "epoch_milli"
    },
    {
      "fieldName": "category",
      "functionSpec": "identity"
    },
    {
      "fieldName": "user_id",
      "functionSpec": "bucket",
      "bucketCount": 16
    },
    {
      "fieldName": "product_code",
      "functionSpec": "truncate",
      "width": 4
    }
  ]
}
```

FieldName

Chaîne UTF-8 (1 à 128 octets) spécifiant le nom de colonne à utiliser pour le partitionnement.

FunctionSpec

Spécifie la fonction de partitionnement. Valeurs valides :

- **identity**- Utilise les valeurs source directement sans transformation
- **year**- Extrait l'année à partir des valeurs d'horodatage (par exemple, 2023)
- **month**- Extrait le mois à partir des valeurs d'horodatage (par exemple, 2023-01)
- **day**- Extrait le jour à partir des valeurs d'horodatage (par exemple, 15/01/2023)
- **hour**- Extrait l'heure des valeurs d'horodatage (par exemple, 15/01/2023)
- **bucket**- Distribue les valeurs dans un nombre spécifié de compartiments à l'aide d'un partitionnement basé sur le hachage. Nécessite un **bucketCount** paramètre.
- **truncate**- Tronque les valeurs de chaîne à une largeur spécifiée. Nécessite un **width** paramètre.

Note

Les fonctions basées sur le temps (`year`, `month`, `day`, `hour`) nécessitent le `ConversionSpec` paramètre pour spécifier le format d'horodatage de la source. Les `truncate` fonctions `bucket` et nécessitent des paramètres supplémentaires, comme indiqué dans leurs descriptions.

ConversionSpec

Chaîne UTF-8 qui spécifie le format d'horodatage des données sources. Les valeurs valides sont :

- `epoch_sec`- Horodatage de l'époque Unix en secondes
- `epoch_milli`- Horodatage de l'époque Unix en millisecondes
- `iso`- Horodatage au format ISO 8601

BucketCount

Entier qui indique le nombre de compartiments à créer lors de l'utilisation de la `bucket` fonction. Ce paramètre est obligatoire lorsqu'il `functionSpec` est défini sur `bucket`. La valeur doit être un nombre entier positif. Le découpage basé sur le hachage répartit les valeurs de manière uniforme sur le nombre de compartiments spécifié.

Exemple Exemple de partitionnement de compartiments

```
{
  "partitionSpec": [
    {
      "fieldName": "user_id",
      "functionSpec": "bucket",
      "bucketCount": 16
    }
  ]
}
```

Largeur

Nombre entier qui indique la largeur de troncature lors de l'utilisation de la `truncate` fonction. Ce paramètre est obligatoire lorsqu'il `functionSpec` est défini sur `truncate`. La valeur doit être

un entier positif représentant le nombre de caractères à retenir depuis le début des valeurs de chaîne.

Exemple Exemple de partitionnement tronqué

```
{
  "partitionSpec": [
    {
      "fieldName": "product_code",
      "functionSpec": "truncate",
      "width": 4
    }
  ]
}
```

Stratégies de partitionnement

Partitionnement par défaut

Lorsqu'aucune colonne de partition n'est spécifiée, AWS Glue Zero-ETL applique des stratégies de partitionnement par défaut optimisées pour votre source de données :

- **Partitionnement basé sur les clés primaires** : pour les sources dotées de clés primaires (telles que les tables DynamoDB), AWS Glue Zero-ETL partitionne automatiquement les données à l'aide de la clé primaire avec des compartiments afin d'éviter l'explosion des partitions.

Le partitionnement par défaut est conçu pour fonctionner correctement pour les modèles de requêtes courants sans nécessiter de configuration manuelle. Toutefois, pour des modèles de requêtes ou des exigences de performances spécifiques, vous souhaitez peut-être définir des stratégies de partitionnement personnalisées.

Stratégies de partitionnement définies par l'utilisateur

AWS Glue Zero-ETL vous permet de définir des stratégies de partitionnement personnalisées à l'aide du `PartitionSpec` paramètre. Vous pouvez spécifier une ou plusieurs colonnes de partition et appliquer différentes fonctions de partitionnement à chaque colonne.

Le partitionnement d'identité utilise les valeurs brutes d'une colonne pour créer des partitions. Cette stratégie est utile pour les colonnes dont la cardinalité est faible à moyenne, telles que les champs de catégorie, de région ou de statut.

Exemple Exemple de partitionnement d'identité

```
{
  "partitionSpec": [
    {
      "fieldName": "category",
      "functionSpec": "identity"
    }
  ]
}
```

Cela crée des partitions distinctes pour chaque valeur unique dans la colonne « catégorie ».

Warning

Évitez d'utiliser le partitionnement d'identité avec des colonnes à cardinalité élevée (comme les clés primaires ou les horodatages), car cela peut entraîner une explosion des partitions, ce qui dégrade les performances et augmente la surcharge de métadonnées.

Le partitionnement basé sur le temps organise les données en fonction des valeurs d'horodatage selon différentes granularités (année, mois, jour ou heure). Cette stratégie est idéale pour les données de séries chronologiques et permet des requêtes temporelles efficaces.

Lors de l'utilisation du partitionnement basé sur le temps, AWS Glue Zero-ETL peut convertir automatiquement différents formats d'horodatage en un format standardisé avant d'appliquer la fonction de partition. Cette conversion est spécifiée à l'aide du `ConversionSpec` paramètre.

Exemple Exemple de partitionnement basé sur le temps

```
{
  "partitionSpec": [
    {
      "fieldName": "created_at",
      "functionSpec": "month",
      "conversionSpec": "epoch_milli"
    }
  ]
}
```

Cela partitionne les données par mois en fonction de la colonne « created_at », qui contient les horodatages d'époque Unix en millisecondes.

AWS Glue Zero-ETL prend en charge les fonctions de partition temporelles suivantes :

- année : Partitionne les données par année (par exemple, 2023, 2024)
- mois : partitionne les données par mois (par exemple, 2023-01, 2023-02)
- jour : Partitionne les données par jour (par exemple, 01/01/2023, 02/01/2023)
- heure : Partitionne les données par heure (par exemple, 01-01-01, 2023-01-01-02)

AWS Glue Zero-ETL prend en charge les formats d'horodatage suivants via le paramètre : `ConversionSpec`

- epoch_sec : horodatages d'époque Unix en secondes
- epoch_milli : horodatages d'époque Unix en millisecondes
- iso : horodatages au format ISO 8601

Note

Les valeurs de colonne d'origine restent inchangées dans vos données source. AWS Glue transforme uniquement les valeurs des colonnes de partition en type Timestamp dans la table de base de données cible. Les transformations s'appliquent uniquement au processus de partitionnement.

Le partitionnement des compartiments utilise la distribution basée sur le hachage pour répartir les données de manière uniforme sur un nombre fixe de compartiments. Cette stratégie est utile pour les colonnes à cardinalité élevée où vous souhaitez contrôler le nombre de partitions et garantir une distribution uniforme des données.

Exemple Exemple de partitionnement de compartiments

```
{
  "partitionSpec": [
    {
      "fieldName": "user_id",
      "functionSpec": "bucket",
      "bucketCount": 16
    }
  ]
}
```

```
}  
]  
}
```

Cela crée 16 compartiments basés sur les valeurs de hachage de la colonne « user_id », garantissant ainsi une distribution uniforme quelles que soient les valeurs réelles de l'identifiant utilisateur.

Le partitionnement des compartiments est particulièrement efficace pour :

- Colonnes à haute cardinalité telles que les clés utilisateur IDs, de session IDs ou primaires
- Scénarios dans lesquels vous avez besoin d'un nombre de partitions prévisible
- Charges de travail bénéficiant d'un traitement parallèle au-delà de limites de partition fixes

Le partitionnement tronqué crée des partitions basées sur des valeurs de chaîne tronquées, en ne conservant que les N premiers caractères. Cette stratégie est utile pour les colonnes de chaînes dans lesquelles vous souhaitez regrouper des valeurs similaires.

Exemple Exemple de partitionnement tronqué

```
{  
  "partitionSpec": [  
    {  
      "fieldName": "product_code",  
      "functionSpec": "truncate",  
      "width": 4  
    }  
  ]  
}
```

Cela crée des partitions basées sur les 4 premiers caractères de la colonne « product_code ». Par exemple, « ELEC12345 » et « ELEC6789 0 » seraient regroupés dans la même partition « ELEC ».

Le partitionnement tronqué est particulièrement efficace pour :

- Codes de produit ou autres identifiants structurés avec des préfixes significatifs SKUs
- Codes géographiques ou codes postaux lorsque le regroupement régional est avantageux
- Toute colonne de chaîne où le regroupement basé sur les préfixes s'aligne sur les modèles de requête

Le partitionnement à plusieurs niveaux combine plusieurs stratégies de partition pour créer un schéma de partitionnement hiérarchique. Cela est utile pour optimiser différents types de requêtes par rapport au même ensemble de données.

Exemple Exemple de partitionnement à plusieurs niveaux

```
{
  "partitionSpec": [
    {
      "fieldName": "created_at",
      "functionSpec": "month",
      "conversionSpec": "iso"
    },
    {
      "fieldName": "region",
      "functionSpec": "identity"
    },
    {
      "fieldName": "user_id",
      "functionSpec": "bucket",
      "bucketCount": 8
    }
  ]
}
```

Cela crée un schéma de partitionnement à trois niveaux : d'abord par mois (à partir de la colonne « created_at »), puis par région et enfin par compartiments d'ID utilisateur. Cela permet des requêtes efficaces qui filtrent par plages de dates, régions spécifiques, segments d'utilisateurs ou toute combinaison de ces dimensions.

Lorsque vous concevez des schémas de partitionnement à plusieurs niveaux, tenez compte des points suivants :

- Placer les colonnes à haute sélectivité en premier dans la hiérarchie des partitions
- Équilibrer la granularité des partitions avec le nombre de partitions
- Aligner le schéma de partitionnement sur vos modèles de requêtes les plus courants

Bonnes pratiques

Sélection de la colonne de partition

- N'utilisez pas de colonnes à cardinalité élevée avec la fonction de `identity partition`. L'utilisation de colonnes à haute cardinalité avec partitionnement des identités crée de nombreuses petites partitions, ce qui peut considérablement dégrader les performances d'ingestion. Les colonnes à haute cardinalité peuvent inclure :
 - Clés primaires
 - Champs d'horodatage (tels `LastModifiedTimestamp` que,) `CreatedDate`
 - Horodatages générés par le système
- Ne sélectionnez pas plusieurs partitions d'horodatage sur la même colonne. Par exemple :

```
"partitionSpec": [  
  {"fieldName": "col1", "functionSpec": "year", "conversionSpec" :  
    "epoch_milli"},  
  {"fieldName": "col1", "functionSpec": "month", "conversionSpec" :  
    "epoch_milli"},  
  {"fieldName": "col1", "functionSpec": "day", "conversionSpec" : "epoch_milli"},  
  {"fieldName": "col1", "functionSpec": "hour", "conversionSpec" : "epoch_milli"}  
]
```

FunctionSpec/ConversionSpec Sélection de partitions

- Spécifiez le format correct `ConversionSpec` (`epoch_sec` | `epoch_milli` | `iso`) qui représente le format des valeurs de colonne choisies pour le partitionnement basé sur l'horodatage lors de l'utilisation de fonctions de partition basées sur l'horodatage. AWS Glue Zero-ETL utilise ce paramètre pour transformer correctement les données source au format d'horodatage avant le partitionnement.
- Utilisez la granularité appropriée (`year/month/day/hour`) en fonction du volume de données.
- Tenez compte des implications du fuseau horaire lorsque vous utilisez des horodatages ISO. AWS Glue Zero-ETL remplit toutes les valeurs d'enregistrement de la colonne d'horodatage choisie avec le fuseau horaire UTC.
- Lorsque vous utilisez le `bucket` partitionnement, choisissez un nombre de compartiments correspondant à vos exigences en matière de parallélisme des requêtes. Les nombres courants de compartiments sont des puissances de 2 (8, 16, 32) pour une distribution de hachage optimale.

- Pour le `truncate` partitionnement, sélectionnez des valeurs de largeur qui créent des groupements significatifs en fonction de vos modèles de données. Assurez-vous que la largeur de troncature capture la partie préfixe significative de vos valeurs de chaîne.
- Évitez d'utiliser `bucket` ou `truncate` de fonctionner comme seule stratégie de partition pour de très petits ensembles de données, car cela peut entraîner une surcharge de partition inutile.

Gestion des erreurs

État `NEEDS_ATTENTION`

Une intégration passe à l'état `NEEDS_ATTENTION` lorsque :

- Les colonnes de partition spécifiées n'existent pas dans la source
- La conversion d'horodatage échoue pour les colonnes de partition

Limites

Limites de partitionnement

- Les spécifications de partition ne peuvent pas être modifiées après la création d'une intégration. Pour utiliser une stratégie de partitionnement différente, vous devez créer une nouvelle intégration.
- Le nombre maximum de colonnes de partition est limité à 10.

Limites de l'intégration entre comptes

- Lors de la création d'intégrations entre comptes, AWS la console Glue est limitée par le fait qu'elle n'invoque pas d' `CreateIntegrationTableProperty` API pour configurer `UnnestSpec` et `PartitionSpec` pour cibler les tables AWS Glue hébergées sur le compte où l'intégration n'existe pas.

Solution : L' `CreateIntegrationTableProperty` API doit être invoquée par CX depuis le compte sur lequel se trouve la base de données cible.

Limites liées aux intégrations multiples

- Si vous devez répliquer la même source avec des `unnest/partition` configurations de schéma différentes, il est nécessaire de créer une nouvelle base de données AWS Glue séparément pour


chaque intégration. Invoquez ensuite `CreateIntegrationTableProperty` pour chaque table à partir de AWS la base de données Glue individuelle avec les configurations de dénidification et de partitionnement du schéma souhaitées.

Tâches d'intégration courantes

Création d'une intégration

Cette section décrit les étapes générales de création d'une intégration. Cet exemple utilise Amazon DynamoDB comme source.

1. Sur la page d'accueil de la AWS Glue console, sélectionnez Zero-ETL integrations.
2. Vous pouvez consulter toutes vos intégrations sur la page d'accueil de l'intégration Zero ETL. Pour créer une nouvelle intégration, sélectionnez Créer une intégration Zero-ETL.



3. Vous êtes invité à sélectionner un type de source. Sélectionnez votre source et cliquez sur Suivant. Reportez-vous aux sections de configuration des sources pour les sources d'intégration SaaS.
 4. Dans la page Configurer la source et la cible, sélectionnez les tables ou les entités à répliquer. Pour Amazon DynamoDB, assurez-vous que la politique PITR et RBAC est configurée.
 5. Spécifiez votre objectif d'intégration :
 - Pour une cible de catalogue de AWS Glue données, sélectionnez la AWS Glue base de données dans laquelle vous souhaitez répliquer les données.
 - Pour une cible d'entrepôt de données Amazon Redshift, sélectionnez l'espace de noms du cluster Redshift ou l'espace de nom du groupe de travail Redshift Serverless.
- Pour de plus amples informations, veuillez consulter [Configuration de l'intégration avec votre cible](#).
6. Indiquez le rôle IAM cible que vous avez créé dans les conditions préalables.
 7. Si vous souhaitez configurer une clé KMS cible facultative pour les données stockées dans la cible, fournissez une clé KMS activée. De même, si vous souhaitez configurer une connexion réseau cible, sélectionnez-en une AWS Glue .
 8. Le bouton Fix Target configure certaines des étapes de la section Prérequis de cette documentation. À savoir, il fournira 1) une politique RBAC du catalogue et 2) si aucun URI Amazon S3 n'est fourni, il en générera une pour vous, sinon il utilisera l'URI fourni.
 9. Pour les intégrations avec une cible d'entrepôt de données Redshift :
 - 10 Dans la section Paramètres de sortie de la page Configurer la source et la cible, sélectionnez l'option de désimbrication du schéma que vous souhaitez pour vos données dans la cible. Si vous souhaitez utiliser des clés de partition client pour vos données, sélectionnez Spécifier des clés de partition personnalisées et fournissez jusqu'à 10 clés. Sinon, vous pouvez simplement utiliser les clés de partition attribuées à votre table DynamoDB en cours de réplication.
 - 11 Dans la section Sécurité et chiffrement des données, vous pouvez fournir une clé KMS qui sera utilisée dans le processus intermédiaire de réplication de vos données vers la cible. Dans le cas contraire, une clé KMS AWS gérée sera utilisée. Actuellement, nous ne prenons en charge qu'un paramètre de réplication de 15 minutes. Entrez un nom pour l'intégration Zero ETL dans les détails de l'intégration.
 12. Vérifiez et assurez-vous que tous les détails fournis sont corrects. Cliquez sur Créer et lancez l'intégration une fois que tout a été confirmé.
 - 13 Sur la page d'accueil de Zero ETL, vous pouvez sélectionner l'intégration que vous avez créée et les détails de vos intégrations apparaîtront. Le « Statut » indique l'état de votre intégration.

Modifier une intégration

Vous pouvez modifier une intégration existante.

1. Sélectionnez Modifier dans le coin supérieur droit de la page des détails de votre intégration.
2. Sur la page Modifier la source et la cible, vous pouvez modifier le rôle Target IAM et la connexion réseau Target. Les autres champs ne sont pas modifiables après la création de l'intégration. Cliquez sur Next (Suivant).
3. Vous pouvez également modifier le nom et la description de l'intégration sur la page Modifier l'intégration et la configuration. Cliquez sur Next (Suivant).
4. Passez en revue vos modifications et, une fois confirmées, cliquez sur Mettre à jour l'intégration.

Supprimer une intégration

Supprimer est un état terminal pour une intégration. Une fois supprimée, l'intégration ne peut pas être rétablie. La suppression d'une intégration efface toutes les métadonnées internes et toutes les données stockées intermédiaires.

Au cours de ce processus, toutes les tâches en cours d'exécution qui écrivent des données dans une table cible sont interrompues. AWS Glue ne supprimera ni ne nettoiera la AWS Glue base de données cible (dans le catalogue de données) ni les données associées dans le compartiment Amazon S3 de votre compte. Vous devez les nettoyer explicitement si nécessaire.

Pour supprimer une intégration :

1. Sur la page des détails de l'intégration, cliquez sur Supprimer.
2. Entrez « Supprimer » et cliquez sur Supprimer. Remarque : Il s'agit d'une action irréversible.
3. Sur la page des détails de l'intégration, le statut indique « Suppression ». Une fois l'intégration supprimée, elle n'apparaîtra plus sur la page d'accueil de l'intégration Zero ETL.

Création d'intégrations à l'aide du APIs

Vous pouvez utiliser ce qui suit APIs pour créer et gérer des intégrations sans ETL dans : AWS Glue

- CreateIntegration
- CreateIntegrationTableProperties

- CreateIntegrationResourceProperty
- UpdateIntegrationTableProperties
- UpdateIntegrationResourceProperty
- ModifyingIntegration
- DeleteIntegration
- DeleteIntegrationTableProperties
- DescribeIntegrations
- DescribeInboundIntegrations
- GetIntegrationTableProperties
- GetIntegrationResourceProperty

Pour de plus amples informations, veuillez consulter [Intégration APIs dans AWS Glue](#).

Surveillance d'une intégration

États d'intégration

Les états d'intégration suivants décrivent l'intégration :

- **Creating-** L'intégration est en cours de création.
- **Active-** L'intégration consiste à envoyer des données transactionnelles à la cible.
- **Modifying-** L'intégration est en cours de modification.
- **Syncing-** L'intégration a rencontré une erreur récupérable et est en train de réensemencer les données.
- **Needs attention-** L'intégration a rencontré un événement ou une erreur nécessitant une intervention manuelle pour le résoudre. Pour résoudre le problème, suivez les instructions du message d'erreur relatif aux détails de l'intégration.
- **Failed-** L'intégration a rencontré un événement ou une erreur irrécupérable. Vous devez supprimer et recréer l'intégration.
- **Deleting-** L'intégration est en cours de suppression.

Consulter CloudWatch les journaux Amazon pour une intégration

AWS Glue Les intégrations sans ETL génèrent des CloudWatch journaux Amazon pour avoir une meilleure visibilité sur le mouvement de vos données. Les événements de journal relatifs à chaque ingestion réussie ou à tout échec dû à des enregistrements de données problématiques à la source, ou à des erreurs d'écriture de données dues à des modifications de schéma ou à des autorisations insuffisantes sont transmis à un groupe de journaux par défaut créé dans un compte client.

Pour chaque intégration créée, les événements du journal correspondant à cette intégration seront collectés `/aws-glue/zeroETL-integrations/logs/` dans Amazon Cloudwatch. Au sein du groupe de journaux, les messages de journal seront divisés en flux de journaux. Chaque intégration créée possède un flux de journal dédié dans lequel sont écrits tous les journaux de cette intégration. Par exemple, les journaux d'une intégration avec `arn:aws:glue:us-east-1:123456789012:integration:03cabe77-79e7-4b7a-b3da-8c160bea6bbf` se trouvent sous `/aws-IntegrationArn arn:aws:glue:us-east-1:123456789012:integration:03cabe77-79e7-4b7a-b3da-8c160bea6bbf.glue/zeroETL-integrations/logs {IntegrationId}` peut être référencé à partir du `{integrationArn}` généré lors de la création d'une intégration.

Note

Dans un scénario entre comptes, les journaux de traitement source sont émis dans le compte source où existe l'intégration et les journaux de traitement cible sont émis dans le compte cible où se trouve la base de données cible.

Autorisations IAM requises pour activer la journalisation

Lors de la création de votre intégration, les rôles source et cible ont besoin des autorisations IAM suivantes pour activer la CloudWatch journalisation d'une intégration. AWS Glue Les intégrations Zero-ETL utilisent ces autorisations fournies dans les rôles source et cible pour émettre des CloudWatch journaux sur les comptes clients.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
```

```

        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents",
    ],
    "Resource": [
        "*"
    ]
}
]
}

```

Messages de journaux

Format de journal : les intégrations sans ETL émettent quatre types de messages de journal :

```

// Ingestion started
{
  "integrationArn": "arn:aws:glue:us-east-2:123456789012:integration/1a012bba-123a-1bba-ab1c-173de3b12345",
  ...
  "messageType": "IngestionStarted",
  "details": {
    "tableName": "testDDBTable",
    "message": "Ingestion Job started"
  }
}
// Data processing stats on successful table ingestion
{
  ...
  "messageType": "IngestionProcessingStats",
  "details": {
    "tableName": "testDDBTable",
    "insert_count": 100,
    "update_count": 10,
    "delete_count": 10
  }
}
// Ingestion failure logs for failed table-processing
{
  ...
  "messageType": "IngestionFailed",
  "details": {
    "tableName": "testDDBTable",

```

```
        "errorMessage": "Failed to ingest data with error: Target Glue database not  
found.",  
        "error_code" : "client_error"  
    }  
}  
// Ingestion completed notification with lastSyncedTimestamp  
{  
    ...  
    "messageType": "IngestionCompleted",  
    "details": {  
        "tableName": "testDDBTable",  
        "message": "Ingestion Job completed"  
        "lastSyncedTimestamp": "1132344255745"  
    }  
}
```

Afficher CloudWatch les statistiques Amazon pour une intégration

Une fois l'intégration terminée, vous pouvez voir les statistiques Amazon Cloudwatch générées dans votre compte pour chaque AWS Glue tâche exécutée :

CloudWatch espace de noms des métriques : "AWS/glue/ZeroEtl »

Dimensions des métriques :

- integrationArn
- loadType
- tableName

Noms des métriques :

- InsertCount- nombre d'enregistrements insérés dans la table Iceberg cible.
- UpdateCount- nombre d'enregistrements mis à jour dans la table Iceberg cible.
- DeleteCount- nombre d'enregistrements supprimés de la table Iceberg cible.
- IngestionSucceeded- compte 1, si l'ingestion a réussi pour l'intégration.
- IngestionFailed- compte 1, si l'ingestion a échoué pour l'intégration.
- LastSyncTimestamp- horodatage jusqu'à quel point la source a été synchronisée avec la cible.

Gérer les notifications d'événements avec Amazon EventBridge

Les intégrations Zero-ETL utilisent Amazon EventBridge pour gérer les notifications d'événements afin de vous tenir au courant up-to-date des modifications apportées à vos intégrations. Amazon EventBridge est un service de bus d'événements sans serveur que vous pouvez utiliser pour connecter vos applications à des données provenant de diverses sources. Dans ce cas, la source de l'événement est AWS Glue. Les événements, qui sont des modifications surveillées dans un environnement, sont EventBridge envoyés AWS Glue automatiquement vers Les événements sont diffusés en temps quasi réel.

EventBridge fournit un environnement dans lequel vous pouvez écrire des règles d'événements, qui peuvent spécifier les actions à entreprendre pour des événements spécifiques. Vous pouvez également définir des cibles, c'est-à-dire des ressources auxquelles un événement EventBridge peut être envoyé. Une cible peut inclure une destination d'API, un groupe de CloudWatch journaux Amazon, etc. Pour plus d'informations sur les règles, consultez les [EventBridge règles d'Amazon](#). Pour plus d'informations sur les cibles, consultez la section [Amazon EventBridge Targets](#).

Pour capturer toutes les notifications Zero-ETL, créez une règle Eventbridge correspondant aux critères suivants :

```
{
  "source": [{
    "prefix": "aws.glue-zero-etl"
  }],
  "detail-type": [{
    "prefix": "Glue Zero ETL"
  }]
}
```

Le tableau suivant inclut des événements d'intégration zéro ETL, avec des métadonnées supplémentaires :

Type de détail destiné au client	Explication
L'ingestion de Glue Zero ETL est terminée	L'exécution individuelle pour une entité s'est terminée avec succès.

Type de détail destiné au client	Explication
Echec de l'ingestion de Glue Zero ETL	L'exécution individuelle d'une entité s'est terminée sans succès (en raison d'une erreur du client ou du système).
Intégration ETL de Glue Zero resynchronisée	L'intégration a été RESYNCHRONISÉE.
L'intégration ETL de Glue Zero a échoué	Le statut de l'intégration est passé à ÉCHEC en raison d'une erreur.
L'intégration ETL de Glue Zero nécessite une attention particulière	Le statut de l'intégration est passé à NEEDS_ATTENTION en raison d'une erreur.

Limites

Les limitations ou considérations générales relatives aux intégrations sans ETL sont les suivantes :

- Les propriétés des ressources ont une one-to-one relation avec la ressource correspondante. Par conséquent, toutes les intégrations créées à l'aide de cette ressource doivent respecter la propriété de ressource singulière. La modification d'une propriété de ressource aura donc un impact sur toutes les intégrations associées à cette ressource.
- Les propriétés de table ont une one-to-one relation avec la table ou l'objet correspondant au sein d'une ressource. Par conséquent, toutes les intégrations qui traitent la même table vers ou depuis la même ressource doivent respecter la propriété de table singulière.
- Vous ne pouvez pas renommer une colonne à la source. Si une colonne est renommée, il n'y a aucune garantie que la détection du schéma sera effectuée avec précision AWS Glue et les répercussions sur l'intégration ne sont pas définies.
- La considération suivante s'applique au fonctionnement de l'intégration avec les tables AWS Lake Formation gérées : Par défaut, vous utilisez la AWS Glue politique IAM/ pour gérer votre table et vos bases de données.
- Si vous souhaitez utiliser AWS Lake Formation pour gérer la création de tables dans cette base de données, vous devez vous assurer que le rôle dispose des autorisations Lake Formation suffisantes pour créer, modifier et supprimer la table et la base de données.
- La page récapitulative Zero-ETL ne contient aucune métrique pour le moment.

Les limites des intégrations zéro-ETL spécifiques à la source sont les suivantes :

- Les intégrations sans ETL avec une OData source SAP prennent désormais en charge les entités commençant par. EntityOf La possibilité de remplacer la clé primaire n'est actuellement prise en charge que pour les SAPOData EntityOf objets. Une fois cette propriété définie, elle ne peut pas être modifiée.
- Les intégrations sans ETL entre Amazon DynamoDB et SageMaker Amazon Lakehouse (via S3) prennent en charge une taille de table DynamoDB maximale de 50 To.
- La table DynamoDB source doit être chiffrée avec une clé KMS appartenant à Amazon ou gérée par le client. AWS Le chiffrement géré par Amazon n'est pas pris en charge pour la table DynamoDB source.
- SAP OData utilise un jeton delta, où la combinaison d'un OAuth client et d'une entité, ou d'une authentification de base associée à une entité, ne peut avoir qu'un seul jeton delta. Évitez d'utiliser la même entité dans deux intégrations différentes avec le même client.
- Les entités ou champs Salesforce suivants ne sont pas pris en charge pour une utilisation dans le cadre d'une intégration zéro ETL avec une source Salesforce.

AccountChangeEvent, AccountContactRoleChangeEvent, AccountHistory, AccountShare, ActiveFeatureLicenseMetric, ActivePermSetLicenseMetric, ActiveProfileMetric, ActivityFieldHistory, amzsec__asi_Telemetry_Data_Store__ChangeEvent, amzsec__asi_Telemetry_Data_Store__History, amzsec__asi_Telemetry_Data_Store__Share, amzsec__asi_Telemetry_Job_Log__ChangeEvent, amzsec__asi_Telemetry_Job_Log__History, amzsec__asi_Telemetry_Job_Log__Share, amzsec__asi_Telemetry_Requirement__ChangeEvent, amzsec__asi_Telemetry_Requirement__History, amzsec__asi_Telemetry_Requirement__Share, ApexClass, ApexComponent, ApexLog, ApexPage, ApexTestQueueItem, ApexTestResult, ApexTrigger, AssetChangeEvent, AssetHistory, AssetRelationshipHistory, AssetShare, AssignmentRule, AssociatedLocationHistory, AsyncApexJob, AuditTrailFileExportShare, AuthorizationFormConsentChangeEvent, AuthorizationFormConsentHistory, AuthorizationFormConsentShare, AuthorizationFormDataUseHistory, AuthorizationFormDataUseShare, AuthorizationFormHistory, AuthorizationFormShare, AuthorizationFormTextHistory, AuthProvider, AuthSession, BatchJobHistory, BatchJobPartFailedRecordHistory, BatchJobPartHistory, BatchJobShare, BrandTemplate, BriefcaseAssignmentChangeEvent, BriefcaseDefinitionChangeEvent, BusinessBrandShare, BusinessHours, BusinessProcess, CalcMatrixColumnRangeHistory, CalcProcStepRelationshipHistory, CalculationMatrixColumnHistory, CalculationMatrixHistory, CalculationMatrixRowHistory, CalculationMatrixShare, CalculationMatrixVersionHistory, CalculationProcedureHistory, CalculationProcedureShare, CalculationProcedureStepHistory,

CalculationProcedureVariableHistory, CalculationProcedureVersionHistory, Calendar, CalendarViewShare, CallCenter, CallCoachConfigModifyEvent, CampaignChangeEvent, CampaignHistory, CampaignMemberChangeEvent, CampaignMemberStatusChangeEvent, CampaignShare, CaseChangeEvent, CaseHistory, CaseHistory2 CaseHistory2ChangeEvent, CaseRelatedIssueChangeEvent, CaseRelatedIssueHistory, CaseShare, CaseStatus, CaseTeamMember, CaseTeamRole, CaseTeamTemplate, CaseTeamTemplateMember, CaseTeamTemplateRecord, CategoryNode, ChangeRequestChangeEvent, ChangeRequestHistory, ChangeRequestRelatedIssueChangeEvent, ChangeRequestRelatedIssueHistory, ChangeRequestRelatedItemChangeEvent, ChangeRequestRelatedItemHistory, ChangeRequestShare, ChatRetirementRdyMetrics, ChatterActivity, ClientBrowser, CollaborationGroup, CollaborationGroupMember, CollaborationGroupMemberRequest, CollaborationInvitation, CommSubscriptionChannelTypeHistory, CommSubscriptionChannelTypeShare, CommSubscriptionConsentChangeEvent, CommSubscriptionConsentHistory, CommSubscriptionConsentShare, CommSubscriptionHistory, CommSubscriptionShare, CommSubscriptionTimingHistory, Community, ConnectedApplication, ContactChangeEvent, ContactHistory, ContactPointAddressChangeEvent, ContactPointAddressHistory, ContactPointAddressShare, ContactPointConsentChangeEvent, ContactPointConsentHistory, ContactPointConsentShare, ContactPointEmailChangeEvent, ContactPointEmailHistory, ContactPointEmailShare, ContactPointPhoneChangeEvent, ContactPointPhoneHistory, ContactPointPhoneShare, ContactPointTypeConsentChangeEvent, ContactPointTypeConsentHistory, ContactPointTypeConsentShare, ContactRequestShare, ContactShare, ContentDocumentChangeEvent, ContentDocumentHistory, ContentDocumentLink, ContentDocumentLinkChangeEvent, ContentDocumentSubscription, ContentFolderItem, ContentFolderLink, ContentFolderMember, ContentNote, ContentNotification, ContentTagSubscription, ContentUserSubscription, ContentVersionChangeEvent, ContentVersionComment, ContentVersionHistory, ContentVersionRating, ContentWorkspace, ContentWorkspaceMember, ContentWorkspacePermission, ContentWorkspaceSubscription, ContractChangeEvent, ContractHistory, ContractLineItemChangeEvent, ContractLineItemHistory, ContractStatus, Conversation, ConversationParticipant, CronJobDetail, CronTrigger, CustomBrand, CustomBrandAsset, CustomerShare, CustomHTTPHeader, DashboardComponent, DataUseLegalBasisHistory, DataUseLegalBasisShare, DataUsePurposeHistory, DataUsePurposeShare, DecisionTableRecordset, DeleteEvent, DocumentAttachmentMap, Domain, DomainSite, DTRecordsetReplicaShare, EmailBounceEvent, EmailMessageChangeEvent, EmailServicesAddress, EmailServicesFunction, EmailTemplate, EmailTemplateChangeEvent, EngagementAttendeeChangeEvent, EngagementAttendeeHistory, EngagementChannelTypeHistory, EngagementChannelTypeShare, EngagementInteractionChangeEvent, EngagementInteractionHistory, EngagementInteractionShare, EngagementInterface, EngagementTopicChangeEvent, EngagementTopicHistory, EntitlementChangeEvent, EntitlementHistory, EntitlementTemplate, EntityMilestoneHistory, EntitySubscription, EventChangeEvent, EventRelationChangeEvent, EventRelayConfigChangeEvent, ExpressionSetHistory,

ExpressionSetShare, ExpressionSetVersionHistory, ExternalEventMappingShare, FeedAttachment, FeedLike, FeedPollChoice, FeedPollVote, FeedSignal, FieldPermissions, FieldSecurityClassification, FiscalYearSettings, FlowInterviewLogShare, FlowInterviewShare, FlowOrchestrationEvent, FlowOrchestrationInstanceShare, FlowOrchestrationStageInstanceShare, FlowOrchestrationStepInstanceShare, FlowOrchestrationWorkItemShare, FlowRecordShare, FlowRecordVersionChangeEvent, FlowTestResultShare, Folder, Group, GroupMember, Holiday, IdeaComment, IdpEventLog, ImageHistory, ImageShare, IncidentChangeEvent, IncidentHistory, IncidentRelatedItemChangeEvent, IncidentRelatedItemHistory, IncidentShare, IndividualChangeEvent, IndividualHistory, IndividualShare, KnowledgeableUser, LeadChangeEvent, LeadHistory, LeadShare, LeadStatus, LightningExitByPageMetrics, LightningToggleMetrics, LightningUsageByAppTypeMetrics, LightningUsageByBrowserMetrics, LightningUsageByFlexiPageMetrics, LightningUsageByPageMetrics, ListEmailChangeEvent, ListEmailShare, ListView, LocationChangeEvent, LocationHistory, LocationShare, LocationTrustMeasureShare, LoginHistory, LoginIp, MacroChangeEvent, MacroHistory, MacroInstructionChangeEvent, MacroShare, MacroUsageShare, ManagedContentVariantChangeEvent, MessagingEndUserHistory, MessagingEndUserShare, MessagingSessionHistory, MessagingSessionShare, MilestoneType, MLEngagementEvent, ObjectPermissions, OpportunityChangeEvent, OpportunityContactRoleChangeEvent, OpportunityFieldHistory, OpportunityLineItemChangeEvent, OpportunityShare, OpportunityStage, OrderChangeEvent, OrderHistory, OrderItemChangeEvent, OrderItemHistory, OrderShare, OrderStatus, Organization, OrgEmailAddressSecurity, OrgWideEmailAddress, OutgoingEmail, OutgoingEmailRelation, PackageLicense, PartnerRole, PartyConsentChangeEvent, PartyConsentHistory, PartyConsentShare, Period, PermissionSet, PermissionSetAssignment, PermissionSetTabSetting, Pricebook2ChangeEvent, Pricebook2History, PricebookEntryChangeEvent, PricebookEntryHistory, PrivacyJobSessionShare, PrivacyObjectSessionShare, PrivacyRTBFRequestHistory, PrivacyRTBFRequestShare, PrivacySessionRecordFailureShare, ProblemChangeEvent, ProblemHistory, ProblemIncidentChangeEvent, ProblemIncidentHistory, ProblemRelatedItemChangeEvent, ProblemRelatedItemHistory, ProblemShare, ProcessDefinition, ProcessExceptionEvent, ProcessExceptionShare, ProcessInstanceChangeEvent, ProcessInstanceStep, ProcessInstanceStepChangeEvent, ProcessNode, Product2ChangeEvent, Product2History, ProductEntitlementTemplate, Profile, ProfileSkillEndorsementHistory, ProfileSkillHistory, ProfileSkillShare, ProfileSkillUserHistory, PromptActionShare, PromptErrorShare, QueueSubject, QuickTextChangeEvent, QuickTextHistory, QuickTextShare, QuickTextUsageShare, RecentlyViewed, RecommendationChangeEvent, RecordActionHistory, RecordAlertHistory, RecordAlertShare, RecordType, ScorecardShare, SellerHistory, SellerShare, ServiceContractChangeEvent, ServiceContractHistory, ServiceContractShare, SetupAuditTrail, SetupEntityAccess, SharingRecordCollectionShare, Site, SiteHistory, SiteRedirectMapping, SocialPersonaHistory, SocialPostChangeEvent, SocialPostHistory, SocialPostShare, SolutionHistory, SolutionStatus, StaticResource, StreamingChannelShare,

TableauHostMappingShare, TaskChangeEvent, TaskPriority, TaskStatus, ThreatDetectionFeedback, TimelineObjectDefinitionChangeEvent, TodayGoalShare, Topic, TopicUserEvent, Translation, User, UserAppMenuCustomizationShare, UserChangeEvent, UserDefinedLabelAssignmentShare, UserDefinedLabelShare, UserEmailPreferredPersonShare, UserLicense, UserLogin, UserPackageLicense, UserPreference, UserPrioritizedRecordShare, UserProvisioningRequestShare, UserRole, UserShare, VideoCallChangeEvent, VideoCallParticipantChangeEvent, VideoCallRecordingChangeEvent, VideoCallShare, VisualforceAccessMetrics, VoiceCallChangeEvent, VoiceCallRecordingChangeEvent, VoiceCallShare, Vote, WebLink, WorkAccessShare, WorkBadgeDefinitionHistory, WorkBadgeDefinitionShare, WorkOrderChangeEvent, WorkOrderHistory, WorkOrderLineItemChangeEvent, WorkOrderLineItemHistory, WorkOrderLineItemStatus, WorkOrderShare, WorkOrderStatus, WorkPlanChangeEvent, WorkPlanHistory, WorkPlanShare, WorkPlanTemplateChangeEvent, WorkPlanTemplateEntryChangeEvent, WorkPlanTemplateEntryHistory, WorkPlanTemplateHistory, WorkPlanTemplateShare, WorkStepChangeEvent, WorkStepHistory, WorkStepStatus, WorkStepTemplateChangeEvent, WorkStepTemplateHistory, WorkStepTemplateShare, WorkThanksShare

- Les ServiceNow entités ou champs suivants ne sont pas pris en charge pour une utilisation dans le cadre d'une intégration zéro ETL avec une ServiceNow source.

ais_acl_overrides, ais_async_genius_result, ais_async_request, ais_connection, ais_genius_result_configuration_parameters, ais_partition_health, ais_partition_health_response, ais_publish_history, ais_relevancy_training_execution, ais_relevancy_training_staging, ais_search_profile_relevancy_model, catalog_draft_entities, clone_log, clone_log0000, clone_log0001, clone_log0002, clone_log0003, clone_log0004, clone_log0005, clone_log0006, clone_log0007, cmdb_ie_context, cmdb_ie_log, cmdb_ie_run, cmdb_ire_partial_payloads_index, cmdb_qb_result_base \$par1, cmdb\$par1, discovery_log, discovery_log0000, discovery_log0001, discovery_log0002, discovery_log0003, discovery_log0004, discovery_log0005, discovery_log0006, discovery_log0007, ecc_agent_log, entitlement_data, entl_subscription_map, gs_entitlement_plugin_mapping, ih_transaction_exclusion, import_log, import_log0000, import_log0001, import_log0002, import_log0003, import_log0004, import_log0005, import_log0006, import_log0007, jrobin_archive, jrobin_database, jrobin_datasource, jrobin_definition, jrobin_graph, jrobin_graph_line, jrobin_graph_set, jrobin_graph_set_member, jrobin_shard, jrobin_shard_location, license_role_discovery_run, logger_configuration_validation, m2m_analytics_event_logger, m2m_user_consent_info, ml_artifact_object_store, np\$sys_gen_ai_filter_sample, np\$sys_ui_element, np\$sys_ui_list_element, one_api_service_plan_feature_invocation, one_api_service_plan_invocation, open_nlu_predict_log, open_nlu_predict_log0000, open_nlu_predict_log0001, open_nlu_predict_log0002, open_nlu_predict_log0003, open_nlu_predict_log0004,

open_nlu_predict_log0005, open_nlu_predict_log0006, open_nlu_predict_log0007,
pa_diagnostic_log, pa_diagnostic_log0000, pa_diagnostic_log0001,
pa_diagnostic_log0002, pa_diagnostic_log0003, pa_diagnostic_log0004,
pa_diagnostic_log0005, pa_diagnostic_log0006, pa_diagnostic_log0007, pa_favorites,
pa_job_log_rows, pa_job_log_rows0000, pa_job_log_rows0001, pa_job_log_rows0002,
pa_job_log_rows0003, pa_job_log_rows0004, pa_job_log_rows0005, pa_job_log_rows0006,
pa_job_log_rows0007, pa_migration_ignored_scores, pa_scores_l1, pa_scores_l2,
pa_scores_migration_groups, par_dashboard_conversion_backup, promin_log,
promin_log0000, promin_log0001, promin_log0002, promin_log0003, promin_log0004,
promin_log0005, promin_log0006, promin_log0007, promin_request_object,
proposed_change_verification_log, proposed_change_verification_log0000,
proposed_change_verification_log0001, proposed_change_verification_log0002,
proposed_change_verification_log0003, proposed_change_verification_log0004,
proposed_change_verification_log0005, proposed_change_verification_log0006,
proposed_change_verification_log0007, protected_table_log, protected_table_log0000,
protected_table_log0001, protected_table_log0002, protected_table_log0003,
protected_table_log0004, protected_table_log0005, protected_table_log0006,
protected_table_log0007, pwd_history, qb_query_results, scan_log,
scan_log0000, scan_log0001, scan_log0002, scan_log0003, scan_log0004,
scan_log0005, scan_log0006, scan_log0007, schema_validator_error,
sla_repair_log_entry, sla_repair_log_entry0000, sla_repair_log_entry0001,
sla_repair_log_entry0002, sla_repair_log_entry0003, sla_repair_log_entry0004,
sla_repair_log_entry0005, sla_repair_log_entry0006, sla_repair_log_entry0007,
sla_repair_log_message, sla_repair_log_message0000, sla_repair_log_message0001,
sla_repair_log_message0002, sla_repair_log_message0003, sla_repair_log_message0004,
sla_repair_log_message0005, sla_repair_log_message0006, sla_repair_log_message0007,
sn_bm_client_activity, sn_ci_analytics_st_actionable_notifs,
sn_ci_analytics_st_conv_completion_by_cat, sn_ci_analytics_st_conv_dynamic_property,
sn_ci_analytics_st_conversation, sn_ci_analytics_st_count_by_date,
sn_ci_analytics_st_event_occurrence, sn_ci_analytics_st_event_property_value_trend,
sn_ci_analytics_st_issue_auto_resolution, sn_ci_analytics_st_no_clicks,
sn_ci_analytics_st_no_results, sn_ci_analytics_st_property_summary_by_event,
sn_ci_analytics_st_session_count_per_locale, sn_ci_analytics_st_session_duration,
sn_ci_analytics_st_spokes_usage, sn_ci_analytics_st_topic_execution_stats,
sn_ci_analytics_st_topic_occurrence, sn_ci_analytics_st_trending_content,
sn_ci_analytics_st_trending_queries, sn_ci_analytics_st_users,
sn_cs_plugin_signatures, sn_cs_telemetry_log, sn_dfc_application, sn_dfc_product,
sn_employee_position, sn_entitlement_st_subscription_application_family,
sn_entitlement_st_subscription_application_users, sn_hr_sp_st_relevant_for_you,
sn_instance_clone_log, sn_instance_clone_log0000, sn_instance_clone_log0001,
sn_instance_clone_log0002, sn_instance_clone_log0003, sn_instance_clone_log0004,
sn_instance_clone_log0005, sn_instance_clone_log0006, sn_instance_clone_log0007,
sn_km_mr_st_kb_knowledge, sn_me_st_topic, sn_rf_conditional_definition,
sn_rf_evaluation_type, sn_rf_evaluation_type_input, sn_rf_recommendation_action,

```
sn_rf_recommendation_experience, sn_rf_recommendation_history,
sn_rf_recommendation_rule, sn_rf_record_display_configuration,
sn_rf_trend_definition, sn_sub_man_st_account_level_entitlement,
sn_sub_man_st_gen_ai_metadata, sn_sub_man_st_instance_used_assist_count,
sn_sub_man_st_now_assist_creator_instances, sn_sub_man_st_now_assists_aggregate,
sn_sub_man_st_subscribed_groups, sn_sub_man_st_subscription_insights,
sn_sub_man_st_subscription_license_detail_metric,
sn_sub_man_st_unallocated_group_recommendation,
sn_sub_man_st_unconfirmed_user_group, sn_wn_user_app_activity,
sn_wn_user_content_activity, snc_monitorable_item,
snpar_sched_export_v_scheduled_export_visualization, spotlight,
spotlight_audit, spotlight_copy_log_row, spotlight_copy_log_row0000,
spotlight_copy_log_row0001, spotlight_copy_log_row0002, spotlight_copy_log_row0003,
spotlight_copy_log_row0004, spotlight_copy_log_row0005, spotlight_copy_log_row0006,
spotlight_copy_log_row0007, spotlight_job_log_row, spotlight_job_log_row0000,
spotlight_job_log_row0001, spotlight_job_log_row0002, spotlight_job_log_row0003,
spotlight_job_log_row0004, spotlight_job_log_row0005, spotlight_job_log_row0006,
spotlight_job_log_row0007, st_dfc_performance_metric, st_license_detail_metric,
st_on_call_hour, st_sc_wizard_question, st_sys_catalog_items_and_variable_sets,
st_sys_design_system_icon, subscription_instance_stats,
svc_container_config, svc_environment_config, svc_layer_config,
svc_model_assoc_ci, svc_model_checkpoint_attr, svc_model_obj_cluster,
svc_model_obj_constraint, svc_model_obj_deployable, svc_model_obj_element,
svc_model_obj_impact, svc_model_obj_impactrule, svc_model_obj_package,
svc_model_obj_path, svc_model_obj_relation, svc_model_obj_service,
sys_administrative_script_transaction, sys_amb_message, sys_amb_processor,
sys_analytics_batch_state, sys_analytics_config, sys_analytics_data_points_error,
sys_analytics_event, sys_analytics_logger, sys_analytics_logger_field,
sys_app_payload_loader_rule, sys_app_payload_unloader_rule, sys_app_scan_payload,
sys_app_scan_variable, sys_app_scan_variable_type, sys_archive_destroy_log,
sys_archive_destroy_run, sys_archive_log, sys_archive_run, sys_atf_transaction_log,
sys_attachment_doc, sys_attachment_doc_v2, sys_attachment_soft_deleted, sys_audit,
sys_audit_relation, sys_auth_policy_api_allowed, sys_aw_registered_scripting_modal,
sys_cache_flush, sys_data_egress_source, sys_dm_delete_count,
sys_export_set_log, sys_export_set_log0000, sys_export_set_log0001,
sys_export_set_log0002, sys_export_set_log0003, sys_export_set_log0004,
sys_export_set_log0005, sys_export_set_log0006, sys_export_set_log0007,
sys_flow_compiled_flow, sys_flow_compiled_flow_chunk, sys_flow_context_chunk,
sys_flow_context_chunk_archive, sys_flow_context_inputs_chunk,
sys_flow_execution_history, sys_flow_log, sys_flow_log0000, sys_flow_log0001,
sys_flow_log0002, sys_flow_log0003, sys_flow_plan_context_binding,
sys_flow_report_doc, sys_flow_report_doc_chunk, sys_flow_report_doc_chunk_archive,
sys_flow_runtime_state_chunk, sys_flow_runtime_value_chunk,
sys_flow_subflow_plan_chunk, sys_flow_trigger_plan_chunk, sys_flow_val_listener,
```



```

sys_flow_value, sys_flow_value_chunk, sys_gen_ai_config_example,
sys_gen_ai_feature_mapping, sys_gen_ai_strategy_mapping, sys_gen_ai_usage_log,
sys_generative_ai_capability_definition, sys_generative_ai_log,
sys_generative_ai_response_validator, sys_generative_ai_validator,
sys_geo_routing, sys_geo_routing_config, sys_hop_token, sys_hub_action_plan_chunk,
sys_hub_snapshot_chunk, sys_journal_field, sys_journal_field_edit, sys_json_chunk,
sys_kaa_policy, sys_kaa_subidentity_assertion, sys_kaa_user_policy_mapping,
sys_mapapplication, sys_mass_encryption_job, sys_notification_execution_log,
sys_notification_execution_log0000, sys_notification_execution_log0001,
sys_notification_execution_log0002, sys_notification_execution_log0003,
sys_notification_execution_log0004, sys_notification_execution_log0005,
sys_notification_execution_log0006, sys_notification_execution_log0007,
sys_nowmq_message, sys_nowmq_provider_param_definition, sys_orchestrator_action,
sys_pd_asset_configuration, sys_pd_context_chunk, sys_pd_context_log,
sys_pd_snapshot_chunk, sys_pd_trigger_license, sys_processing_framework_job,
sys_query_index_hint, sys_query_rewrite, sys_query_string_log,
sys_replication_queue, sys_replication_queue0, sys_replication_queue1,
sys_replication_queue2, sys_replication_queue3, sys_replication_queue4,
sys_replication_queue5, sys_replication_queue6, sys_replication_queue7,
sys_request_performance, sys_rollback_blacklisted, sys_rollback_conflict,
sys_rollback_incremental, sys_rollback_log, sys_rollback_log0000,
sys_rollback_log0001, sys_rollback_log0002, sys_rollback_log0003,
sys_rollback_log0004, sys_rollback_log0005, sys_rollback_log0006,
sys_rollback_log0007, sys_rollback_run, sys_rollback_schema_change,
sys_rollback_schema_conflict, sys_rollback_sequence, sys_scheduler_assignment,
sys_scheduler_memory_pressure_job_log, sys_script_adapter_rule,
sys_script_batch_adapter_rule, sys_search_source_filter, sys_service_authentication,
sys_signing_job, sys_suggestion_reader, sys_sync_history_review, sys_trend,
sys_unreferenced_preview, sys_unreferenced_record_rule, sys_upgrade_manifest,
sys_upgrade_state, sys_ux_asset_cache_buster, sys_ux_lib_component_prop,
sys_ux_lib_presource, sys_ux_page_action, sys_ux_page_action_binding,
sys_sevent_queue_runtime, syslog, syslog_app_scope0000, syslog_app_scope0001,
syslog_app_scope0002, syslog_app_scope0003, syslog_app_scope0004,
syslog_app_scope0005, syslog_app_scope0006, syslog_app_scope0007, syslog_email0000,
syslog_email0001, syslog_email0002, syslog_email0003, syslog_email0004,
syslog_email0005, syslog_email0006, syslog_email0007, syslog_transaction,
syslog_transaction0000, syslog_transaction0001, syslog_transaction0002,
syslog_transaction0003, syslog_transaction0004, syslog_transaction0005,
syslog_transaction0006, syslog_transaction0007, syslog0000, syslog0001,
syslog0002, syslog0003, syslog0004, syslog0005, syslog0006, syslog0007,
ts_attachment, ts_c_1_0, ts_c_1_1, ts_c_1_2, ts_c_1_3, ts_c_1_4, ts_c_1_5,
ts_c_1_6, ts_c_1_7, ts_c_1_8, ts_c_1_9, ts_c_10_0, ts_c_10_1, ts_c_10_2,
ts_c_10_3, ts_c_10_4, ts_c_10_5, ts_c_10_6, ts_c_10_7, ts_c_10_8, ts_c_10_9,
ts_c_11_0, ts_c_11_1, ts_c_11_2, ts_c_11_3, ts_c_11_4, ts_c_11_5, ts_c_11_6,

```

```

ts_c_11_7, ts_c_11_8, ts_c_11_9, ts_c_2_0, ts_c_2_1, ts_c_2_2, ts_c_2_3,
ts_c_2_4, ts_c_2_5, ts_c_2_6, ts_c_2_7, ts_c_2_8, ts_c_2_9, ts_c_3_0,
ts_c_3_1, ts_c_3_2, ts_c_3_3, ts_c_3_4, ts_c_3_5, ts_c_3_6, ts_c_3_7, ts_c_3_8,
ts_c_3_9, ts_c_39_0, ts_c_39_1, ts_c_39_2, ts_c_39_3, ts_c_39_4, ts_c_39_5,
ts_c_39_6, ts_c_39_7, ts_c_39_8, ts_c_39_9, ts_c_40_0, ts_c_40_1, ts_c_40_2,
ts_c_40_3, ts_c_40_4, ts_c_40_5, ts_c_40_6, ts_c_40_7, ts_c_40_8, ts_c_40_9,
ts_c_41_0, ts_c_41_1, ts_c_41_2, ts_c_41_3, ts_c_41_4, ts_c_41_5, ts_c_41_6,
ts_c_41_7, ts_c_41_8, ts_c_41_9, ts_c_42_0, ts_c_42_1, ts_c_42_2, ts_c_42_3,
ts_c_42_4, ts_c_42_5, ts_c_42_6, ts_c_42_7, ts_c_42_8, ts_c_42_9, ts_c_43_0,
ts_c_43_1, ts_c_43_2, ts_c_43_3, ts_c_43_4, ts_c_43_5, ts_c_43_6, ts_c_43_7,
ts_c_43_8, ts_c_43_9, ts_c_44_0, ts_c_44_1, ts_c_44_2, ts_c_44_3, ts_c_44_4,
ts_c_44_5, ts_c_44_6, ts_c_44_7, ts_c_44_8, ts_c_44_9, ts_c_45_0, ts_c_45_1,
ts_c_45_2, ts_c_45_3, ts_c_45_4, ts_c_45_5, ts_c_45_6, ts_c_45_7, ts_c_45_8,
ts_c_45_9, ts_c_6_0, ts_c_6_1, ts_c_6_2, ts_c_6_3, ts_c_6_4, ts_c_6_5,
ts_c_6_6, ts_c_6_7, ts_c_6_8, ts_c_6_9, ts_c_7_0, ts_c_7_1, ts_c_7_2, ts_c_7_3,
ts_c_7_4, ts_c_7_5, ts_c_7_6, ts_c_7_7, ts_c_7_8, ts_c_7_9, ts_c_8_0, ts_c_8_1,
ts_c_8_2, ts_c_8_3, ts_c_8_4, ts_c_8_5, ts_c_8_6, ts_c_8_7, ts_c_8_8, ts_c_8_9,
ts_c_attachment, ts_chain, ts_deleted_doc, ts_document, ts_field, ts_index_stats,
ts_phrase, ts_search_stats, ts_v4_attachment, ts_word, ua_app_metadata,
ua_audit_stats, ua_extra_page, ua_monitor_property, ua_monitor_property_audit,
ua_shared_service, ua_sn_table_inventory, ua_sp_known_bot, ua_upload_log,
v_ais_result_improvement_rule_condition_builder_values, v_cluster_nodes,
v_cxs_search_resource, v_db_index, v_db_trigger, v_file_load_order,
v_interaction_context, v_iostats, v_mysql_proclist, v_mysql_status,
v_mysql_variables, v_on_call_report_cache, v_pa_par_combined_dashboard,
v_pd_activity_condition_to_run, v_pd_activity_start_rule_with_condition,
v_pd_lane_condition_to_run, v_sql_debug, v_st_kb_category, v_st_kb_most_viewed,
v_st_kb_recently_viewed, v_st_km_genai_mra_similar_task, v_st_popular_item,
v_st_recent_item, v_st_sc_cat_item, v_st_sc_catalog, v_st_sc_category,
validator_run_summary, vtb_card_history, wf_log, wf_log0000, wf_log0001,
wf_log0002, wf_log0003, wf_log0004, wf_log0005, wf_log0006, wf_log0007,
spotlight_criteria, pa_snapshots, pa_widget_indicators, pa_widgets,
sn_cim_register, global, gsw_change_log, gsw_content, gsw_content_group,
gsw_content_information, gsw_status_of_content, multi_factor_browser_fingerprint,
multi_factor_criteria, pa_filters, password_policy, plan_execution,
plan_mysql, plan_oracle, plan_postgres, sc_rest_api_without_access_policy,
sn_actsub_activity, sn_actsub_activity_fanout, sn_actsub_activity_stream,
sn_actsub_activity_type, sn_actsub_atype_attributes, sn_actsub_atype_notif_pref,
sn_actsub_module, sn_actsub_notif_object, sn_actsub_subobject_stream,
sn_actsub_subscribable_object, sn_actsub_subscription_notif_pref,
sn_actsub_user_stream, sn_appclient_store_outbound_http_quota,
sn_appcreator_app_template, sn_critical_update, sn_docker_spoke_images,
sn_employee_app, sn_employee_app_access, sn_employee_app_access_criteria,
sn_entitlement_genai_assist_counts, sn_entitlement_genai_creator_user_counts,

```

```
sn_entitlement_genai_creator_users, sn_mif_instance, sn_mif_sync_data,  
sn_mif_sync_status, sn_mif_table_registration, sn_mif_trust_config,  
sn_vsc_best_practice_configurations, sn_vsc_best_practice_goals,  
sn_vsc_changed_hardening_settings, sn_vsc_changed_scan_findings,  
sn_vsc_check_security_area, sn_vsc_elevation_event, sn_vsc_event,  
sn_vsc_export_event, sn_vsc_export_setting, sn_vsc_harc_compliance_status_lookup,  
sn_vsc_hardening_compliance_scores, sn_vsc_impersonation_event,  
sn_vsc_instance_hardening_settings, sn_vsc_login_event,  
sn_vsc_scan_comparisons, sn_vsc_scan_summary, sn_vsc_security_check_categories,  
sn_vsc_security_check_configurations, sn_vsc_security_configuration_groups,  
sn_vsc_security_privacy_capabilities, sn_vsc_updated_settings,  
sn_vsc_user_comparisons, sys_app_hash_inventory, sys_coalesce_strategy_deferred,  
sys_flow_secure_data, sys_formula_function, sys_geocoding_request,  
sys_global_file_hash, sys_import_set_row, sys_index, sys_index_explain,  
sys_installation_schedule, sys_installation_schedule_item, sys_offline_app,  
sys_package, sys_package_dependency_item, sys_package_dependency_m2m,  
sys_plugins, sys_querystat, sys_reap_package, sys_scoped_plugin,  
sys_stage_storage_alias, sys_storage_alias, sys_storage_table_alias, sys_store_app,  
sys_table_partition, sys_upgrade_history_log, sys_user_public_credential,  
sys_webauthn_authentication_request, sys_webauthn_registration_request,  
syslog_app_scope, syslog_email, syslog_page_timing, ua_instance_state_config,  
v_expression_cache, v_private_cache, v_shared_cache, sys_amb_message0002,  
sys_amb_message0004, sys_amb_message0005, sys_metadata, v_par_unified_report_viz
```

AWS Glue Qualité des données

AWS Glue La qualité des données vous permet de mesurer et de surveiller la qualité de vos données afin de prendre de bonnes décisions commerciales. Construit sur le DeeQu framework open source, AWS Glue Data Quality fournit une expérience gérée et sans serveur. AWS Glue Data Quality fonctionne avec le langage DQDL (Data Quality Definition Language), qui est un langage spécifique au domaine que vous utilisez pour définir des règles de qualité des données. Pour en savoir plus sur le langage DQDL et les types de règles pris en charge, consultez [Référence DQDL \(Data Quality Definition Language\)](#).

Pour plus d'informations sur les produits et les tarifs, consultez la page de service relative à [AWS Glue Data Quality](#).

Avantages et fonctionnalités clés

Les avantages et les principales caractéristiques de la qualité AWS Glue des données sont les suivants :

- Sans serveur : aucune installation, aucun correctif ni aucune maintenance ne sont nécessaires.
- Démarrez rapidement — AWS Glue Data Quality analyse rapidement vos données et crée des règles de qualité pour vous. Vous pouvez commencer en deux clics : « Créer des règles de qualité des données → Recommander des règles ».
- Détectez les problèmes de qualité des données : utilisez l'apprentissage automatique (ML) pour détecter les anomalies et les problèmes de qualité des hard-to-detect données.
- Improvisez vos règles : avec plus de 25 règles out-of-the-box DQ à partir de laquelle vous pouvez commencer, vous pouvez créer des règles adaptées à vos besoins spécifiques.
- Évaluer la qualité et prendre des décisions métier en toute confiance : une fois les règles évaluées, vous obtenez un score de qualité des données qui vous donne une vue d'ensemble de l'état de vos données. Utilisez le score de qualité des données pour prendre des décisions métier en toute confiance.
- Concentrez-vous sur les données erronées : la qualité AWS Glue des données vous aide à identifier les enregistrements exacts qui ont entraîné une baisse de vos scores de qualité. Identifiez-les facilement, mettez-les en quarantaine et corrigez-les.
- Payez au fur et à mesure : aucune licence annuelle n'est nécessaire pour utiliser AWS Glue Data Quality.

- Pas de blocage : AWS Glue Data Quality repose sur l'open source DeeQu, ce qui vous permet de conserver les règles que vous créez dans un langage ouvert.
- Contrôles de qualité des données — Vous pouvez appliquer des contrôles de qualité des données sur Data Catalog les pipelines AWS Glue ETL, ce qui vous permet de gérer la qualité des données au repos et en transit.
- Détection de la qualité des données basée sur le ML : utilisez l'apprentissage automatique (ML) pour détecter les anomalies et les problèmes de qualité hard-to-detect des données.
- Langage ouvert pour exprimer les règles : garantit que les règles de qualité des données sont créées de manière cohérente et simple. Les utilisateurs professionnels peuvent facilement exprimer les règles de qualité des données dans un langage clair et compréhensible. Pour les ingénieurs, ce langage offre la flexibilité nécessaire pour générer du code, implémenter un contrôle de version cohérent et automatiser les déploiements.

Comment ça marche

Il existe deux points d'entrée pour la qualité AWS Glue des données : les jobs AWS Glue ETL AWS Glue Data Catalog et les jobs. Cette section fournit un aperçu des cas d'utilisation et des AWS Glue fonctionnalités pris en charge par chaque point d'entrée.

Qualité des données pour le AWS Glue Data Catalog

AWS Glue Data Quality évalue les objets stockés dans le. AWS Glue Data Catalog Cela permet aux non-codeurs de configurer facilement des règles de qualité des données. Ces personas incluent les gestionnaires de données et des analystes métier.

Vous pouvez choisir cette option pour les cas d'utilisation suivants :

- Vous souhaitez effectuer des tâches de qualité des données sur des jeux de données que vous avez déjà catalogués dans AWS Glue Data Catalog.
- Vous travaillez sur la gouvernance des données et avez besoin d'identifier ou d'évaluer en permanence les problèmes de qualité des données dans votre lac de données.

Vous pouvez gérer la qualité des données du catalogue de données à l'aide des interfaces suivantes :

- La console AWS Glue de gestion
- AWS Glue APIs

Pour commencer à utiliser AWS Glue Data Quality for the AWS Glue Data Catalog see [Démarrage avec AWS Glue Data Quality pour le Data Catalog](#).

Qualité des données pour les tâches AWS Glue ETL

AWS Glue La qualité des données pour les tâches AWS Glue ETL vous permet d'effectuer des tâches proactives de qualité des données. Les tâches proactives vous aident à identifier et à filtrer les données défectueuses avant de charger un jeu de données dans votre lac de données.

[Vidéo : Présentation de la qualité AWS Glue des données pour les pipelines ETL](#)

Vous pouvez choisir la qualité des données pour les tâches ETL dans les cas d'utilisation suivants :

- Vous souhaitez intégrer des tâches de qualité des données dans vos tâches ETL
- Vous souhaitez écrire du code qui définit les tâches de qualité des données dans les scripts ETL
- Vous souhaitez gérer la qualité des données qui circulent dans vos pipelines de données visuels

Vous pouvez gérer la qualité des données pour les tâches ETL à l'aide des interfaces suivantes :

- AWS Glue Studio, AWS Glue Studio carnets de notes et sessions AWS Glue interactives
- AWS Glue bibliothèques pour les scripts ETL
- AWS Glue APIs

Pour commencer à utiliser la qualité des données pour les tâches ETL, consultez [Tutorial: Getting started with Data Quality](#) dans le Guide de l'utilisateur AWS Glue Studio .

Comparaison entre la qualité des données du catalogue de données et la qualité des données des tâches ETL

Ce tableau fournit un aperçu des fonctionnalités prises en charge par chaque point d'entrée pour AWS Glue Data Quality.

Fonctionnalité	Qualité des données pour le catalogue de données	Qualité des données pour les tâches ETL
Sources de données	Amazon S3, Amazon Redshift, les sources JDBC compatibles avec le catalogue de données et les formats de lacs de données transactionnels tels qu'Apache Iceberg, Apache Hudi et Delta Lake. Notez que si les tables sont AWS Lake Formation gérées, les tables Iceberg, Delta et HUDI ne sont pas prises en charge. Amazon Athena les vues cataloguées dans le AWS Glue Data Catalog sont pas prises en charge.	Toutes les sources de données sont prises en charge par AWS Glue, y compris les connecteurs personnalisés et les connecteurs tiers.
Recommandations règles de la qualité des données	Pris en charge	Non pris en charge
Rédiger et appliquer les règles DQDL	Pris en charge	Pris en charge
Auto scaling (Mise à l'échelle automatique)	Non pris en charge	Pris en charge
AWS Glue Support flexible	Non pris en charge	Pris en charge
Planification	Pris en charge lors de l'évaluation des règles de la qualité des données et via Step Functions.	Pris en charge lors de l'utilisation des Step Functions et des flux de travail.
Identification des enregistrements ayant échoué aux	Non pris en charge	Pris en charge

Fonctionnalité	Qualité des données pour le catalogue de données	Qualité des données pour les tâches ETL
contrôles de qualité des données		
Intégration à Amazon EventBridge	Pris en charge	Pris en charge
Intégration à AWS Cloudwatch	Pris en charge	Pris en charge
Écrire les résultats de la qualité des données dans Amazon S3	Pris en charge	Pris en charge
Qualité de données incrémentielle	Pris en charge par le pushdown de prédicats	Supporté par les AWS Glue signets
AWS CloudFormation soutien	Pris en charge	Pris en charge
Détection des anomalies basée sur le ML	Non pris en charge	Pris en charge
Règles dynamiques	Non pris en charge	Pris en charge

Considérations

Tenez compte des éléments suivants avant d'utiliser AWS Glue Data Quality :

- Les règles de qualité des données ne peuvent pas évaluer les sources de données imbriquées ou de type liste. Consultez [Aplatissage de structs imbriqués](#).

Terminologie

La liste suivante définit les termes relatifs à la qualité AWS Glue des données.

DQDL (Data Quality Definition Language)

Langage spécifique à un domaine que vous pouvez utiliser pour rédiger des règles de qualité AWS Glue des données.

Pour en savoir plus sur DQDL, consultez le guide [Référence DQDL \(Data Quality Definition Language\)](#).

qualité des données

Décrit dans quelle mesure un ensemble de données répond à son objectif spécifique. AWS Glue La qualité des données évalue les règles par rapport à un ensemble de données afin de mesurer la qualité des données. Chaque règle vérifie des caractéristiques particulières comme l'actualisation ou l'intégrité des données. Pour quantifier la qualité des données, vous pouvez utiliser un score de qualité des données.

score de qualité des données

Pourcentage de règles de qualité des données qui sont satisfaites (aboutissent à un résultat vrai) lorsque vous évaluez un ensemble de règles avec AWS Glue Data Quality.

règle

Expression DQDL qui recherche une caractéristique spécifique dans vos données et renvoie une valeur booléenne. Pour de plus amples informations, veuillez consulter [Structure des règles](#).

analyseur

Expression DQDL qui rassemble des statistiques de données. Un analyseur collecte des statistiques de données qui peuvent être utilisées par les algorithmes de machine learning pour détecter les anomalies et les problèmes de qualité hard-to-detect des données au fil du temps.

jeu de règles

AWS Glue Ressource comprenant un ensemble de règles de qualité des données. Un jeu de règles doit être associé à une table dans AWS Glue Data Catalog. Lorsque vous enregistrez un jeu de règles, AWS Glue lui attribue un Amazon Resource Name (ARN).

score de qualité des données

Pourcentage de règles de qualité des données qui sont respectées (génèrent « true ») lorsque vous évaluez un jeu de règles avec AWS Glue Data Quality.

observation

Un aperçu non confirmé généré par AWS Glue en analysant les statistiques de données rassemblées à partir de règles et d'analyseurs au fil du temps.

Limites

AWS Glue Limites du service de qualité des données :

- Un ensemble de règles peut contenir 2 000 règles. Si vos ensembles de règles sont plus importants, nous vous recommandons de les diviser en plusieurs ensembles de règles.
- La taille de l'ensemble de règles est de 65 Ko. Si vos ensembles de règles sont plus importants, nous vous recommandons de les diviser en plusieurs ensembles de règles.
- AWS Glue Data Quality collecte des statistiques lorsque vous créez une règle ou un analyseur. Le stockage de ces statistiques est gratuit. Cependant, il y a une limite de 100 000 statistiques par compte, et ces statistiques seront conservées pendant un maximum de deux ans.

Notes de publication AWS Glue relatives à la qualité des données

Cette rubrique décrit les fonctionnalités introduites dans AWS Glue Data Quality.

Disponibilité générale : nouvelles fonctionnalités

Les nouvelles fonctionnalités suivantes sont disponibles avec la disponibilité générale de AWS Glue Data Quality :

- La capacité d'identifier les enregistrements ayant échoué aux contrôles de qualité des données est désormais prise en charge dans AWS Glue Studio
- Nouveaux types de règles de qualité des données tels que la validation de l'intégrité référentielle des données entre deux jeux de données, la comparaison des données entre deux jeux de données et les vérifications du type de données.
- Expérience utilisateur améliorée dans le AWS Glue Data Catalog
- Prise en charge d'Apache Iceberg, d'Apache Hudi et de Delta Lake
- Prise en charge d'Amazon Redshift
- Notification simplifiée avec Amazon EventBridge

- AWS CloudFormation support pour la création d'ensembles de règles
- Améliorations des performances : option de mise en cache dans ETL et AWS Glue Studio pour des performances plus rapides lors de l'évaluation de la qualité des données

27 novembre 2023 (aperçu)

- Les fonctionnalités de détection d'anomalies basées sur le ML sont désormais disponibles dans AWS Glue ETL et AWS Glue Studio. Grâce à cela, vous pouvez désormais détecter les anomalies et les problèmes de qualité des hard-to-detect données
- [Les règles dynamiques vous permettent de fournir des seuils dynamiques \(ex :RowCount>avg\(last\(10\)\)\)](#)

12 mars 2024

- Améliorations du DQDL
 - [Support pour des mots clés tels que NULL, BLANKS, WHITESPACES_ONLY](#)
 - [Options permettant de spécifier la manière dont la qualité AWS Glue des données doit gérer les règles composites](#)
 - [ColumnValues le type de règle n'autorisera pas le transfert de valeurs NULL lors des comparaisons](#)
 - [Support pour l'opérateur NOT dans le DQDL](#)

26 juin 2024

- Améliorations du DQDL
 - DQDL prend désormais en charge la [clause Where](#) afin que vous puissiez filtrer les données avant d'appliquer les règles DQ

7 août 2024

- La détection des anomalies et les règles dynamiques sont désormais disponibles pour tous

22 novembre 2024

- [Les règles composites complexes vous permettent de créer des règles métier plus complexes avec un support imbriqué](#)
- Nouveaux types de règles pour gérer la qualité des données de vos fichiers
 - [FileFreshness](#)
 - [FileSize](#)
 - [FileUniqueness](#)
 - [FileMatch](#)
- Contrôles de qualité des données par défaut dans les tâches Visual ETL

6 déc. 2024

- AWS Glue Data Quality prend désormais en charge Amazon SageMaker AI LakeHouse les tables et les tables Iceberg, Delta et HUDI AWS Lake Formation gérées dans AWS Glue ETL 5.0.

30 juin 2025

- Métriques agrégées : vous pouvez désormais obtenir des mesures agrégées telles que le nombre d'enregistrements transmis, d'échecs au niveau de l'API pour les tâches DQ basées sur AWS Glue ETL.

Détection d'anomalies dans AWS Glue Qualité des données

Arguments en faveur du Machine Learning dans le domaine de la qualité des données

Les ingénieurs gèrent des centaines de pipelines de données simultanément. Chaque pipeline peut extraire des données de différentes sources et les charger dans le lac de données ou dans d'autres référentiels de données. Pour garantir la fourniture de données de haute qualité pour la prise de décision, ils établissent des règles de qualité des données. Ces règles évaluent les données sur la base de critères fixes reflétant l'état actuel des affaires. Cependant, lorsque l'environnement commercial change, les propriétés des données changent, ce qui rend ces critères fixes obsolètes et entraîne une mauvaise qualité des données.

Par exemple, un ingénieur des données d'une entreprise de vente au détail a établi une règle qui valide que les ventes quotidiennes doivent dépasser un one-million-dollar certain seuil. Après quelques mois, les ventes quotidiennes ont dépassé les deux millions de dollars, rendant le seuil obsolète. L'ingénieur des données n'a pas pu mettre à jour les règles pour refléter les derniers seuils en raison de l'absence de notification et des efforts nécessaires pour analyser et mettre à jour manuellement la règle. Plus tard dans le mois, les utilisateurs professionnels ont remarqué une baisse de 25 % de leurs ventes. Après des heures d'enquête, les ingénieurs de données ont découvert qu'un pipeline ETL chargé d'extraire les données de certains magasins avait échoué sans générer d'erreurs. La règle dont les seuils étaient périmés a continué de fonctionner correctement sans que ce problème ne soit détecté.


Par ailleurs, des alertes proactives capables de détecter ces anomalies auraient pu permettre aux utilisateurs de détecter ce problème. En outre, le suivi de la saisonnalité dans le monde des affaires peut mettre en évidence d'importants problèmes de qualité des données. Par exemple, les ventes au détail peuvent être les plus élevées le week-end et pendant les fêtes de fin d'année, alors qu'elles sont relativement faibles en semaine. Toute divergence par rapport à ce schéma peut indiquer des problèmes de qualité des données ou des changements dans le contexte commercial. Les règles de qualité des données ne peuvent pas détecter les modèles saisonniers, car cela nécessite des algorithmes avancés capables de tirer des leçons des modèles passés pour capturer la saisonnalité afin de détecter les écarts.

Enfin, les utilisateurs trouvent difficile de créer et de maintenir des règles en raison de la nature technique du processus de création des règles et du temps nécessaire à leur création. Par conséquent, ils préfèrent d'abord explorer les informations relatives aux données avant de définir des règles. Les clients doivent pouvoir détecter facilement les anomalies, ce qui leur permet de détecter de manière proactive les problèmes de qualité des données et de prendre des décisions commerciales en toute confiance.

Comment ça marche

Note

La détection des anomalies n'est prise en charge que dans AWS Glue ETL. Cela n'est pas pris en charge dans la qualité des données basée sur le catalogue de données.



AWS Glue Data Quality combine la puissance de la qualité des données basée sur des règles et des fonctionnalités de détection des anomalies pour fournir des données de haute qualité. Pour commencer, vous devez d'abord configurer les règles et les analyseurs, puis activer la détection des anomalies.

Règles

Règles : les règles expriment les attentes relatives à vos données dans un langage ouvert appelé Data Quality Definition Language (DQDL). Un exemple de règle est présenté ci-dessous. Cette règle sera efficace s'il n'y a aucune valeur vide ou NULL dans la colonne `passenger\_count` :

```
Rules = [
  IsComplete "passenger_count"
]
```

Analyseurs

Dans les situations où vous connaissez les colonnes critiques mais que vous ne connaissez pas suffisamment les données pour écrire des règles spécifiques, vous pouvez surveiller ces colonnes à l'aide d'Analyzers. Les analyseurs permettent de recueillir des statistiques de données sans définir de règles explicites. Voici un exemple de configuration des analyseurs :

```
Analyzers = [
```

```
AllStatistics "fare_amount",  
DistinctValuesCount "pulocationid",  
RowCount  
]
```

Dans cet exemple, trois analyseurs sont configurés :

1. Le premier analyseur, `AllStatistics « fare\_amount »`, capturera toutes les statistiques disponibles pour le champ `fare\_amount`.
2. Le second analyseur, `DistinctValuesCount « pulocationid »`, capturera le nombre de valeurs distinctes dans la colonne « pulocationid ».
3. Le troisième analyseur, `RowCount`, capturera le nombre total d'enregistrements de l'ensemble de données.

Les analyseurs constituent un moyen simple de recueillir des statistiques de données pertinentes sans définir de règles complexes. En surveillant ces statistiques, vous pouvez obtenir des informations sur la qualité des données et identifier les problèmes ou anomalies potentiels qui peuvent nécessiter une enquête plus approfondie ou la création de règles spécifiques.


Statistiques des données

Analyzers et Rules in AWS Glue Data Quality collectent des statistiques de données, également appelées profils de données. Ces statistiques fournissent des informations sur les caractéristiques et la qualité de vos données. Les statistiques collectées sont stockées au fil du temps au sein du service AWS Glue, ce qui vous permet de suivre et d'analyser les modifications de vos profils de données.

Vous pouvez facilement récupérer ces statistiques et les écrire sur Amazon S3 pour une analyse plus approfondie ou un stockage à long terme en invoquant le code approprié APIs. Cette fonctionnalité vous permet d'intégrer le profilage des données dans vos flux de travail de traitement des données et d'exploiter les statistiques collectées à diverses fins, telles que le suivi de la qualité des données, la détection des anomalies.

En stockant les profils de données dans Amazon S3, vous pouvez tirer parti de l'évolutivité, de la durabilité et de la rentabilité du service de stockage d'objets d'Amazon. En outre, vous pouvez tirer parti d'autres AWS services ou d'outils tiers pour analyser et visualiser les profils de données, ce qui vous permet de mieux comprendre la qualité de vos données et de prendre des décisions éclairées en matière de gestion et de gouvernance des données.

Voici un exemple de statistiques de données stockées au fil du temps.




Note

AWS Glue Data Quality ne collectera les statistiques qu'une seule fois, même si vous disposez à la fois de Rule et d'Analyzer pour les mêmes colonnes, ce qui rend le processus de génération de statistiques efficace.

Détection des anomalies

AWS Glue Data Quality nécessite un minimum de trois points de données pour détecter les anomalies. Il utilise un algorithme d'apprentissage automatique pour tirer des leçons des tendances passées, puis prévoir les valeurs futures. Lorsque la valeur réelle ne se situe pas dans la plage prévue, AWS Glue Data Quality crée une observation d'anomalie. Il fournit une représentation visuelle de la valeur réelle et des tendances. Quatre valeurs sont affichées sur le graphique ci-dessous.



1. La statistique réelle et son évolution dans le temps.
2. Une tendance dérivée en tirant des leçons de la tendance réelle. Cela est utile pour comprendre l'orientation de la tendance.
3. Borne supérieure possible pour la statistique.
4. Borne inférieure possible pour la statistique.
5. Règles de qualité des données recommandées permettant de détecter ces problèmes à l'avenir.

Il y a quelques points importants à noter concernant les anomalies :

- Lorsque des anomalies sont générées, les scores de qualité des données ne sont pas affectés.
- Lorsqu'une anomalie est détectée, elle est considérée comme normale pour les essais suivants. L'algorithme d'apprentissage automatique considérera cette valeur anormale comme entrée, sauf si elle est explicitement exclue.

Reconversion

Il est essentiel de réentraîner le modèle de détection des anomalies pour détecter les bonnes anomalies. Lorsque des anomalies sont détectées, AWS Glue Data Quality inclut l'anomalie dans le modèle en tant que valeur normale. Pour garantir le bon fonctionnement de la détection des anomalies, il est important de fournir un feedback en reconnaissant ou en rejetant l'anomalie. AWS Glue Data Quality fournit des mécanismes à la fois dans AWS Glue Studio et APIs pour fournir des

commentaires au modèle. Pour en savoir plus, consultez la documentation sur la configuration de la [détection des anomalies dans les pipelines AWS Glue ETL](#).

Détails de l'algorithme de détection des anomalies

- L'algorithme de détection des anomalies examine les statistiques des données au fil du temps. L'algorithme prend en compte tous les points de données disponibles et ignore les statistiques explicitement exclues.
- Ces statistiques de données sont stockées dans le service AWS Glue, et vous pouvez fournir des AWS KMS clés pour les chiffrer. Reportez-vous au guide de sécurité pour savoir comment fournir des AWS KMS clés pour chiffrer les statistiques de AWS Glue Data Quality.
- La composante temporelle est cruciale pour l'algorithme de détection des anomalies. Sur la base des valeurs passées, AWS Glue Data Quality détermine les limites supérieure et inférieure. Au cours de cette détermination, il prend en compte la composante temporelle. Les limites seront différentes pour les mêmes valeurs sur un intervalle d'une minute, un intervalle horaire ou un intervalle quotidien.

Capter la saisonnalité

AWS L'algorithme de détection des anomalies de Glue Data Quality peut capturer les tendances saisonnières. Par exemple, il peut comprendre que les modèles des jours de semaine diffèrent des modèles du week-end. C'est ce que montre l'exemple ci-dessous, où AWS Glue Data Quality détecte une tendance saisonnière dans les valeurs des données. Il n'est pas nécessaire de faire quoi que ce soit de spécifique pour activer cette fonctionnalité. Au fil du temps, AWS Glue Data Quality apprend les tendances saisonnières et détecte les anomalies lorsque ces tendances se cassent.



Coût

Vous serez facturé en fonction du temps nécessaire pour détecter les anomalies. Chaque statistique est facturée 1 DPU pour le temps nécessaire à la détection des anomalies. Reportez-vous à [AWS la section Glue Pricing](#) pour des exemples détaillés.

Considérations clés

Le stockage des statistiques est gratuit. Cependant, il existe une limite de 100 000 statistiques par compte. Ces statistiques seront conservées pendant deux ans au maximum.

Configurer les autorisations IAM pour AWS Glue Data Quality

Cette rubrique fournit des informations pour vous aider à comprendre les actions et les ressources qu'un administrateur IAM peut utiliser dans le cadre d'une politique AWS Identity and Access Management (IAM) pour AWS Glue Data Quality. Il inclut également des exemples de politiques IAM avec les autorisations minimales dont vous avez besoin pour utiliser AWS Glue Data Quality with the AWS Glue Data Catalog.

Pour plus d'informations sur la sécurité dans AWS Glue, consultez [Sécurité dans AWS Glue](#).

Autorisations IAM pour AWS Glue Data Quality

Le tableau suivant répertorie les autorisations dont les utilisateurs ont besoin pour effectuer des opérations spécifiques avec la qualité des données d' AWS Glue. Pour définir une autorisation précise pour AWS Glue Data Quality, vous pouvez spécifier ces actions dans l'Actionélément d'une déclaration de politique IAM.

AWS Actions de Glue Data Quality

Action	Description	Types de ressources
<code>glue:CreateDataQualityRuleset</code>	Accorde l'autorisation de créer un jeu de règles de qualité des données.	<code>::dataQualityRuleset/<name></code>
<code>glue>DeleteDataQualityRuleset</code>	Accorde l'autorisation de supprimer un jeu de règles de qualité des données.	<code>::dataQualityRuleset/<name></code>
<code>glue:GetDataQualityRuleset</code>	Accorde l'autorisation de récupérer un jeu de règles de qualité des données.	<code>::dataQualityRuleset/<name></code>
<code>glue:ListDataQualityRulesets</code>	Accorde l'autorisation de récupérer tous les jeux de règles de qualité des données.	<code>::dataQualityRuleset/*</code>
<code>glue:UpdateDataQualityRuleset</code>	Accorde l'autorisation de mettre à jour un jeu de règles de qualité des données.	<code>::dataQualityRuleset/<name></code>
<code>glue:GetDataQualityResult</code>	Accorde l'autorisation de récupérer le résultat d'une exécution de tâche liée à la qualité des données. Cette action IAM fournit également des autorisations aux API suivantes :	<code>::dataQualityRuleset/<name></code>

Action	Description	Types de ressources
	- BatchGetDataQualityQualityResult - ListDataQualityStatistics - ListDataQualityStatisticAnnotations	
glue:ListDataQualityResults	Accorde l'autorisation de récupérer tous les résultats d'exécution de tâches liées à la qualité des données.	::dataQualityRules et/*
glue:CancelDataQualityRuleRecommendationRun	Accorde l'autorisation d'arrêter l'exécution d'une tâche de recommandation sur la qualité des données en cours.	::dataQualityRules et/*
glue:GetDataQualityRuleRecommendationRun	Accorde l'autorisation de récupérer l'exécution d'une tâche de recommandation sur la qualité des données.	::dataQualityRules et/*
glue:ListDataQualityRuleRecommendationRuns	Accorde l'autorisation de récupérer toutes les exécutions de tâches de recommandation sur la qualité des données.	::dataQualityRules et/*
glue:StartDataQualityRuleRecommendationRun	Accorde l'autorisation de démarrer l'exécution d'une tâche de recommandation sur la qualité des données.	::dataQualityRules et/*
glue:CancelDataQualityRulesetEvaluationRun	Accorde l'autorisation d'arrêter l'exécution d'une tâche sur la qualité des données en cours.	::dataQualityRules et/*

Action	Description	Types de ressources
<code>glue:GetDataQualityRulesetEvaluationRun</code>	Accorde l'autorisation de récupérer l'exécution de tâches liées à la qualité des données.	<code>::dataQualityRuleset/*</code>
<code>glue:ListDataQualityRulesetEvaluationRuns</code>	Accorde l'autorisation de récupérer toutes les exécutions de tâches liées à la qualité des données.	<code>::dataQualityRuleset/*</code>
<code>glue:StartDataQualityRulesetEvaluationRun</code>	Accorde l'autorisation de démarrer l'exécution d'une tâche liée à la qualité des données.	<code>::dataQualityRuleset/<name></code>
<code>glue:PublishDataQuality</code>	Autorise la publication des résultats relatifs à la qualité des données.	<code>::dataQualityRuleset/<name></code>
<code>glue:GetDataQualityModel</code>	Accorde l'autorisation de récupérer le modèle de qualité des données.	<code>::dataQualityRuleset/<name>, ::job/<name></code>
<code>glue:GetDataQualityModelResult</code>	Accorde l'autorisation de récupérer les résultats du modèle de qualité des données.	<code>::dataQualityRuleset/<name>, ::job/<name></code>

Action	Description	Types de ressources
<code>glue:PutDataQualityStatisticAnnotation</code>	Accorde l'autorisation d'ajouter des annotations aux statistiques. Cette action IAM fournit également des autorisations aux API suivantes : <code>BatchPutDataQualityStatisticAnnotation</code>	<code>::dataQualityRuleset/<name></code> , <code>::job/<name></code>
<code>glue:PutDataQualityProfileAnnotation</code>	Accorde l'autorisation d'ajouter des annotations à toutes les statistiques d'un profil.	<code>::dataQualityRuleset/<name></code> , <code>::job/<name></code>

Configuration IAM requise pour planifier les exécutions d'évaluation

Autorisations IAM

Pour exécuter des exécutions d'évaluation de la qualité des données planifiées, vous devez ajouter l'action `IAM:PassRole` à la politique d'autorisation.

AWS EventBridge Autorisations requises par le planificateur

Action	Description	Types de ressources
<code>iam:PassRole</code>	Permet à IAM d'autoriser l'utilisateur à transmettre les rôles approuvés.	ARN du rôle utilisé pour appeler <code>StartDataQualityRulesetEvaluationRun</code>

Sans ces autorisations, l'erreur suivante se produit :

```
"errorCode": "AccessDenied"
"errorMessage": "User: arn:aws:sts::account_id:assumed-role/AWSGlueServiceRole is not
authorized to perform: iam:PassRole on resource: arn:aws:iam::account_id:role/service-
role/AWSGlueServiceRole"
```

because no identity-based policy allows the iam:PassRole action"

Entités de confiance IAM

Les services AWS Glue et AWS EventBridge Scheduler doivent être répertoriés dans les entités de confiance afin de créer et d'exécuter un planning. StartDataQualityEvaluationRun

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    },
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "scheduler.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

Exemple de politiques IAM

Un rôle IAM pour AWS Glue Data Quality nécessite les types d'autorisations suivants :

- Autorisations pour les opérations de qualité des données de AWS Glue afin que vous puissiez obtenir les règles de qualité des données recommandées et exécuter une tâche de qualité des données par rapport à une table du catalogue de données AWS Glue. Les exemples de politiques IAM présentés dans cette section incluent les autorisations minimales requises pour les opérations de AWS Glue Data Quality.
- Autorisations qui donnent accès à la table de votre catalogue de données et aux données sous-jacentes. Ces autorisations varient en fonction de votre cas d'utilisation. Par exemple, pour les données que vous cataloguez dans Amazon S3, les autorisations doivent inclure l'accès à Amazon S3.

 Note

Vous devez configurer ces autorisations Amazon S3 en plus des autorisations décrites dans cette section.

Autorisations minimales pour obtenir les règles de qualité des données recommandées

Cet exemple de politique inclut les autorisations dont vous avez besoin pour générer des règles de qualité des données recommandées.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "AllowGlueRuleRecommendationRunActions",
      "Effect": "Allow",
      "Action": [
        "glue:GetDataQualityRuleRecommendationRun",
        "glue:PublishDataQuality",
        "glue:CreateDataQualityRuleset"
      ],
      "Resource": "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/*"
    },
    {
      "Sid": "AllowCatalogPermissions",
      "Effect": "Allow",
      "Action": [
        "glue:GetPartitions",
        "glue:GetTable"
      ],
      "Resource": [
        "*"
      ]
    },
    {
      "Sid": "AllowS3GetObjectToRunRuleRecommendationTask",
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ],
    }
  ]
}
```

```

    "Resource": "arn:aws:s3:::aws-glue-*"
  },
  { // Optional for Logs
    "Sid": "AllowPublishingCloudwatchLogs",
    "Effect": "Allow",
    "Action": [
      "logs:CreateLogStream",
      "logs:CreateLogGroup",
      "logs:PutLogEvents"
    ],
    "Resource": "*"
  },
]
}

```

Autorisations minimales pour exécuter une tâche liée à la qualité des données

Cet exemple de politique inclut les autorisations dont vous avez besoin pour exécuter une tâche d'évaluation de la qualité des données.

Les instructions de politique suivantes sont facultatives et dépendent de votre cas d'utilisation :

- `AllowCloudWatchPutMetricDataToPublishTaskMetrics` : obligatoire si vous souhaitez publier des métriques d'exécution sur la qualité des données dans Amazon CloudWatch.
- `AllowS3PutObjectToWriteTaskResults` : obligatoire si vous souhaitez écrire des résultats d'exécution sur la qualité des données dans Amazon S3.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "AllowGlueGetDataQualityRuleset",
      "Effect": "Allow",
      "Action": [
        "glue:GetDataQualityRuleset"
      ],
      "Resource": "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/<YOUR-RULESET-NAME>"
    },
    {
      "Sid": "AllowGlueRulesetEvaluationRunActions",

```

```

    "Effect": "Allow",
    "Action": [
        "glue:GetDataQualityRulesetEvaluationRun",
        "glue:PublishDataQuality"
    ],
    "Resource": "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/*"
  },
  {
    "Sid": "AllowCatalogPermissions",
    "Effect": "Allow",
    "Action": [
        "glue:GetPartitions",
        "glue:GetTable"
    ],
    "Resource": [
        "*"
    ]
  },
  {
    "Sid": "AllowS3GetObjectForRulesetEvaluationRun",
    "Effect": "Allow",
    "Action": [
        "s3:GetObject"
    ],
    "Resource": "arn:aws:s3:::aws-glue-*"
  },
  {
    "Sid": "AllowCloudWatchPutMetricDataToPublishTaskMetrics",
    "Effect": "Allow",
    "Action": [
        "cloudwatch:PutMetricData"
    ],
    "Resource": "*",
    "Condition": {
        "StringEquals": {
            "cloudwatch:namespace": "Glue Data Quality"
        }
    }
  },
  {
    "Sid": "AllowS3PutObjectToWriteTaskResults",
    "Effect": "Allow",
    "Action": [
        "s3:PutObject*"
    ]
  }
}

```

```

    ],
    "Resource": "arn:aws:s3:::<YOUR-BUCKET-NAME>/*"
  }
]
}

```

Autorisations minimales pour exécuter une tâche ETL de qualité des données

Cet exemple de politique inclut les autorisations dont vous avez besoin pour exécuter un Job ETL de qualité des données.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "AllowGluePublishDataQualityResult",
      "Effect": "Allow",
      "Action": [
        "glue:PublishDataQuality"
      ],
      "Resource": "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/*"
    },
    //Optional to retrieve results, observation generation,
    //dynamic rules and DetectAnomalies
    {
      "Sid": "AllowGlueGetDataQualityResult",
      "Effect": "Allow",
      "Action": [
        "glue:GetDataQualityResult"
      ],
      "Resource": "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/*"
    },
    //Optional to allow annotating statistics
    {
      "Sid": "AllowGlueDataQualityStatisticAnnotation",
      "Effect": "Allow",
      "Action": [
        "glue:PutDataQualityStatisticAnnotation"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/*",
        "arn:aws:glue:us-east-1:111122223333:job/{JobName}"
      ]
    }
  ]
}

```

```
},
//Optional to allow annotating all statistics in a profile
{
  "Sid": "AllowGlueDataQualityProfileAnnotation",
  "Effect": "Allow",
  "Action": [
    "glue:PutDataQualityProfileAnnotation"
  ],
  "Resource": [
    "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/*",
    "arn:aws:glue:us-east-1:111122223333::job/{JobName}"
  ]
}
}
```

Démarrage avec AWS Glue Data Quality pour le Data Catalog

Cette section de mise en route fournit des instructions pour vous aider à démarrer avec AWS Glue Data Quality sur le AWS Glue console. Vous apprendrez à accomplir des tâches essentielles telles que la génération de recommandations de règles portant sur la qualité des données et l'évaluation d'un jeu de règles par rapport à vos données.

Rubriques

- [Prérequis](#)
- [Step-by-step exemple](#)
- [Génération de recommandations de règles](#)
- [Recommandations sur les règles de surveillance](#)
- [Modification des ensembles de règles recommandés](#)
- [Création d'un ensemble de règles](#)
- [Exécution d'un jeu de règles pour évaluer la qualité des données](#)
- [Affichage du score de qualité des données et des résultats](#)
- [Rubriques en relation](#)

Prérequis

Avant d'utiliser AWS Glue Data Quality, vous devez être familiarisé avec l'utilisation du Data Catalog et crawlers in AWS Glue. Avec AWS Glue Data Quality, vous pouvez évaluer la qualité des tables dans un Data Catalog base de données. Vous avez également besoin des éléments suivants :

- Une table dans le Data Catalog pour évaluer vos règles de qualité des données par rapport à.
- Un rôle IAM pour AWS Glue que vous fournissez lorsque vous générez des recommandations de règles ou que vous exécutez une tâche de qualité des données. Ce rôle doit être autorisé à accéder à des ressources qui varient AWS Glue Data Quality les processus doivent être exécutés en votre nom. Ces ressources incluent AWS Glue, Amazon S3 et CloudWatch. Pour consulter des exemples de politiques qui incluent les autorisations minimales pour AWS Glue Data Quality, voir [Exemple de politiques IAM](#).

Pour en savoir plus sur les rôles IAM pour AWS Glue, voir [Création d'une politique IAM pour le AWS Glue service](#) et [créez un rôle IAM pour le AWS Glue service](#). Vous pouvez également consulter une liste de tous AWS Glue autorisations spécifiques à la qualité des données dans [Authorization for AWS Glue Data Quality actions](#).

- Une base de données avec au moins une table qui contient une variété de données. La table utilisée dans ce didacticiel est nommée `yyz-tickets`, avec la table `tickets`. Ces données sont une collection d'informations accessibles au public provenant de la ville de Toronto concernant les contraventions de stationnement. Si vous créez votre propre table, assurez-vous qu'elle est alimentée par une variété de données valides afin d'obtenir le meilleur ensemble de règles recommandées.

Step-by-step exemple

Pour un step-by-step exemple avec des exemples de jeux de données, consultez le billet de [blog AWS Glue Data Quality](#).

Génération de recommandations de règles

Les recommandations de règles facilitent l'amélioration de la qualité des données sans écrire de code. Avec la qualité des données d' AWS , vous pouvez analyser vos données, identifier les règles et créer un ensemble de règles que vous pouvez évaluer dans le cadre d'une tâche liée à la qualité des données. Les exécutions de recommandations sont automatiquement supprimées après 90 jours.

Pour générer des recommandations de règles de qualité des données

1. Ouvrez la console AWS Glue à l'adresse <https://console.aws.amazon.com/glue/>.
2. Sélectionnez Tables dans le volet de navigation. Choisissez ensuite la table pour laquelle vous souhaitez générer des recommandations de règles de qualité des données.
3. Sur la page des détails du tableau, sélectionnez l'onglet Data quality pour accéder aux règles et aux paramètres de AWS Glue Data Quality pour votre tableau.
4. Dans l'onglet Qualité des données, choisissez Ajouter des règles et surveiller la qualité des données.
5. Sur la page Générateur d'ensemble règles, une alerte en haut de la page vous invite à démarrer une tâche de recommandation s'il n'y a pas d'exécution de recommandation de règles.
6. Choisissez Recommander des règles pour ouvrir la fenêtre modale et saisir vos paramètres pour la tâche de recommandation.
7. Choisissez un rôle IAM avec accès à AWS Glue. Ce rôle doit être autorisé à accéder aux ressources dont les différents processus de AWS Glue Data Quality ont besoin pour être exécutés en votre nom.
8. Une fois les champs remplis conformément à vos préférences, sélectionnez Recommander des règles pour démarrer l'exécution de la tâche de recommandation. Si des exécutions de recommandation sont en cours ou terminées, vous pouvez gérer vos exécutions dans cette alerte. Il se peut que vous deviez actualiser l'alerte pour afficher le changement du statut. Les exécutions de tâches de recommandation terminées et en cours apparaissent sur la page Historique des exécutions qui répertorie toutes les exécutions de recommandation des 90 derniers jours.

Signification des règles recommandées

AWS Glue Data Quality génère des règles basées sur les données de chaque colonne de la table en entrée. Il utilise les règles pour identifier les limites potentielles dans lesquelles les données peuvent être filtrées afin de respecter les exigences de qualité. La liste suivante de règles générées inclut des exemples utiles pour comprendre la signification des règles et ce qu'elles peuvent faire lorsqu'elles sont appliquées à vos données.

Pour obtenir la liste complète des types de règles DQDL (Data Quality Definition Language) générés, veuillez consulter [Référence des types de règles DQDL](#).

- `IsComplete "SET_FINE_AMOUNT"` : la règle `IsComplete` vérifie que la colonne est remplie pour une ligne donnée. Utilisez cette règle pour marquer les colonnes comme non facultatives dans les données.
- `Uniqueness "TICKET_NUMBER" > 0.95` : la règle `Uniqueness` vérifie que les données de la colonne atteignent un certain seuil d'unicité. Dans cet exemple, il a été déterminé que les données qui remplissent une ligne donnée pour `"TICKET_NUMBER"` étaient identiques à 95 % au maximum à toutes les autres lignes, ce qui suggère cette règle.
- `ColumnValues "PROVINCE" in ["ON", "QC", "AB", "NY", ...]` : la règle `ColumnValues` définit des valeurs valides pour la colonne, en fonction du contenu existant de la colonne. Dans cet exemple, les données de chaque ligne correspondent à un code d'immatriculation à deux lettres pour un état ou une province.
- `ColumnLength "INFRACTION_DESCRIPTION" between 15 and 31` : la règle `ColumnLength` impose une restriction de longueur aux données d'une colonne. Cette règle est générée à partir des échantillons de données en fonction des longueurs minimale et maximale enregistrées pour une colonne de chaînes.

Recommandations sur les règles de surveillance

Lorsque les recommandations de règles de qualité des données sont en cours d'exécution, la page **Ajouter des règles et surveiller la qualité des données** affiche des informations et des actions supplémentaires que vous pouvez effectuer dans la barre supérieure.

Lorsque les recommandations de règles sont en cours, vous pouvez choisir **Arrêter l'exécution** avant que la tâche de recommandation ne soit terminée. Pendant que la tâche est en cours, vous pouvez voir le statut **En cours**, ainsi que la date et l'heure du début de l'exécution.

Lorsque les recommandations de règles sont terminées, la barre de recommandations de règles affiche le nombre de règles recommandées, le statut de la dernière recommandation exécutée, ainsi que la date et l'horodatage de fin.

Vous pouvez ajouter les règles recommandées en choisissant **Insérer une recommandation de règle**. Pour consulter les règles précédemment recommandées, sélectionnez une date précise. Pour exécuter une nouvelle recommandation, sélectionnez **Plus d'actions**, puis sélectionnez **Règles recommandées**.

Définissez les paramètres par défaut en choisissant Gérer les paramètres utilisateur. Vous pouvez définir le chemin par défaut sur Amazon S3 pour stocker les ensembles de règles ou pour configurer un rôle par défaut pour exécuter le catalogue de données.

Modification des ensembles de règles recommandés

Comme la qualité des données d' AWS Glue génère des règles basées sur les données existantes dont vous disposez, il est possible que certaines règles inattendues ou indésirables apparaissent dans les suggestions automatisées. Afin de tirer le meilleur parti des ensembles de règles recommandés, vous devez les évaluer et les modifier. Pour cette étape du didacticiel, vous reprenez les règles générées à l'étape précédente et les ajustez pour appliquer des qualités plus restrictives à certaines données. Vous assouplissez également d'autres règles afin de garantir que des données correctes et uniques puissent être ajoutées ultérieurement.

Modifier un ensemble de règles suggéré

1. Dans la console AWS Glue, choisissez Data Catalog, puis choisissez Databases de données dans le volet de navigation. Choisissez la table `tickets`.
2. Sur la page des détails du tableau, choisissez l'onglet Data quality pour accéder aux règles et aux paramètres de AWS Glue Data Quality pour le tableau.
3. Dans la section Ensembles de règles, sélectionnez l'ensemble de règles généré dans [Génération de recommandations de règles](#).
4. Choisissez Actions, puis sélectionnez Modifier dans la fenêtre de la console. L'éditeur d'ensembles de règles se charge dans la console. Il inclut un volet d'édition pour vos règles et une référence rapide pour DQDL.
5. Supprimer la ligne 2 du script. Cela permet d'assouplir l'exigence selon laquelle la taille de la base de données doit être limitée à un certain nombre de lignes. Après la modification, votre fichier doit contenir les éléments suivants sur les lignes 1 à 3 :

```
Rules = [  
    IsComplete "TAG_NUMBER_MASKED",  
    ColumnLength "TAG_NUMBER_MASKED" between 6 and 9,
```

6. Supprimer la ligne 25 du script. Cela permet d'assouplir l'exigence selon laquelle 96 % des provinces enregistrées sont ON. Après la modification, votre fichier doit contenir les éléments suivants, de la ligne 24 à la fin de l'ensemble de règles :

```
ColumnValues "PROVINCE" in ["ON", "QC", "AB", "NY", "AZ", "NS", "BC", "MI", "PQ",
    "MB", "PA", "FL", "SK", "NJ", "OH", "NB", "IL", "MA", "CA",
    "VA", "TX", "NF", "MD", "PE", "CT", "NC", "GA", "IN", "OR", "MN", "TN", "WI",
    "KY", "MO", "WA", "NH", "SC", "CO", "OK", "VT", "RI", "ME", "AL",
    "YT", "IA", "DE", "AR", "LA", "XX", "WV", "MT", "KS", "NT", "DC", "NV", "NE",
    "UT", "MS", "NM", "ID", "SD", "ND", "AK", "NU", "GO", "WY", "HI"],
ColumnLength "PROVINCE" = 2
]
```

- Changez la ligne 14 comme suit :

```
IsComplete "TIME_OF_INFRACTION",
```

Cela renforce l'exigence relative à la colonne en limitant la base de données aux seules contraventions qui contiennent une heure d'infraction enregistrée. Vous devez toujours considérer les contraventions sans heure d'infraction enregistrée comme des données non valides dans ce jeu de données. Cela diffère des situations dans lesquelles le partitionnement ou la transformation peuvent être plus appropriés pour une utilisation ou une inspection plus poussée des données afin de déterminer une règle de qualité.

- Choisissez Mettre à jour l'ensemble de règles en bas de la page de la console.

Création d'un ensemble de règles

Un jeu de règles est un groupe de règles de qualité des données que vous évaluez par rapport à vos données. Dans le volet AWS Glue console, vous pouvez créer des ensembles de règles personnalisés à l'aide du langage DQDL (Data Quality Definition Language).

Pour créer un jeu de règles de qualité des données

- Dans la console AWS Glue, choisissez Data Catalog, Databases, puis Tables dans le volet de navigation. Sélectionnez la table `tickets`.
- Ouvrez l'onglet Data quality (Qualité des données).
- Dans la section Ensembles de règles choisissez Créer un ensemble de règles. L'éditeur DQDL s'ouvre dans la console. Il dispose d'une zone de texte pour l'édition directe et d'une référence rapide pour les règles DQDL et le schéma de la table.

- Commencez à ajouter des règles dans la zone de texte de l'éditeur DQDL. Vous pouvez soit écrire des règles directement à partir de ce didacticiel, soit utiliser la fonctionnalité du générateur de règles DQDL de l'éditeur de règles de qualité des données.

Note

Comment utiliser le générateur de règles DQDL

- Sélectionnez un type de règle dans la liste, puis choisissez le signe plus pour insérer un exemple de syntaxe dans le volet d'édition.
- Remplacez les noms des colonnes par vos propres noms de colonnes. Les noms des colonnes de la table sont disponibles dans l'onglet Schéma.
- Mettez à jour le paramètre d'expression selon vos besoins. Pour obtenir la liste complète des expressions prises en charge par DQDL, consultez [Expressions](#).

Par exemple, les règles suivantes sont des contraintes pour la validation des données de la colonne `ticket_number` dans la table `tickets`. Pour ajouter les règles suivantes, utilisez le générateur de règles DQDL ou modifiez directement votre ensemble de règles :

```
IsComplete "ticket_number",  
IsUnique "ticket_number",  
ColumnValues "ticket_number" > 9000000000
```

- Fournissez un nom pour votre exécution dans le champ Nom de l'ensemble de règles.
- Choisissez Enregistrer l'ensemble de règles.

Évaluation de la qualité des données sur plusieurs jeux de données

Vous pouvez définir des règles de qualité des données pour plusieurs ensembles de données à l'aide d'ensembles `ReferentialIntegrity` de `DatasetMatch` règles. `ReferentialIntegrity` vérifie si les données du jeu de données principal sont présentes dans d'autres ensembles de données.

Pour ajouter un jeu de données de référence, cliquez sur l'onglet Schéma, puis sur Mettre à jour les tables de référence. Vous serez invité à sélectionner une base de données et une table. Vous pouvez ajouter la table, puis définir des règles de qualité des données. Les types de règles tels que

AggregateMatch RowCountMatch ReferentialIntegrity, SchemaMatch, et permettent DatasetMatch d'effectuer des contrôles de qualité des données sur plusieurs ensembles de données.

Exécution d'un jeu de règles pour évaluer la qualité des données

Lorsque vous exécutez une tâche de qualité des données, AWS Glue Data Quality évalue un ensemble de règles par rapport à vos données et calcule un score de qualité des données. Ce score représente le pourcentage de règles de qualité des données qui ont été acceptées pour l'entrée.

Pour exécuter une tâche liée à la qualité des données

1. Dans la console AWS Glue, choisissez Data Catalog, Databases, puis Tables dans le volet de navigation. Sélectionnez le tableau `tickets`.
2. Choisissez l'onglet Qualité des données.
3. Dans la liste Ensembles de règles, sélectionnez l'ensemble de règles que vous souhaitez évaluer par rapport à la table. Pour cette étape, nous vous recommandons d'utiliser un ensemble de règles que vous avez déjà écrit ou modifié plutôt que des règles générées. Cliquez sur Exécuter.
4. Dans la fenêtre modale, choisissez votre rôle IAM. Ce rôle doit être autorisé à accéder aux ressources dont les différents processus de AWS Glue Data Quality ont besoin pour être exécutés en votre nom. Vous pouvez enregistrer le rôle IAM comme rôle par défaut ou le modifier en accédant à la page Paramètres par défaut.
5. Sous Actions relatives à la qualité des données, indiquez si vous souhaitez publier des statistiques sur Amazon CloudWatch. Lorsque cette option est sélectionnée, AWS Glue Data Quality publie des statistiques qui indiquent le nombre de règles passées et le nombre de règles qui ont échoué. Pour agir sur les métriques stockées de cette manière, vous pouvez utiliser des CloudWatch alarmes. Les indicateurs clés sont également publiés Amazon EventBridge pour vous permettre de configurer des alertes. Pour plus d'informations, consultez [Setting up alerts, deployments, and scheduling](#).
6. Sous Fréquence d'exécution, choisissez d'exécuter à la demande ou de planifier l'ensemble de règles. Lorsque vous planifiez un ensemble de règles, le nom de la tâche vous est demandé. Le calendrier sera créé dans Amazon EventBridge. Vous pouvez modifier votre calendrier dans Amazon EventBridge.
7. Pour enregistrer les résultats dans Amazon S3, choisissez un emplacement pour les résultats de la qualité des données. Le rôle IAM que vous avez précédemment sélectionné pour cette tâche doit disposer d'un accès à cet emplacement.

8. Sous Configurations supplémentaires, entrez le nombre de travailleurs demandé que AWS Glue doit affecter à votre tâche de qualité des données.
9. Vous pouvez éventuellement configurer un filtre au niveau de la source de données. Cela vous permet de réduire le nombre de données que vous lisez. Vous pouvez également utiliser un filtre pour exécuter des validations incrémentielles en sélectionnant des informations de partition et en les transmettant en tant que paramètres via des appels d'API. Pour améliorer les performances, vous pouvez fournir un prédicat de partition.
10. Cliquez sur Exécuter. Votre nouvelle tâche doit apparaître dans la liste Data quality task runs (Exécutions de tâches liées à la qualité des données). Lorsque la colonne Statut d'exécution de la tâche indique Terminé, vous pouvez consulter les résultats du score de qualité. Il se peut que vous deviez rafraîchir votre fenêtre de console pour que le statut soit correctement mis à jour.
11. Pour afficher la colonne contenant les détails des résultats de la qualité des données, cliquez sur l'icône « + » pour développer l'ensemble de règles. Les résultats vous indiquent les règles qui ont réussi et échoué lors de l'évaluation, ainsi que les causes de l'échec des règles.

Affichage du score de qualité des données et des résultats

Pour voir la dernière exécution sur tous les ensembles de règles créés

1. Dans la console AWS Glue, choisissez Tables dans le volet de navigation. Choisissez ensuite la table pour laquelle vous souhaitez exécuter une tâche liée à la qualité des données.
2. Choisissez l'onglet Qualité des données.
3. L'instantané de la qualité des données montre une tendance générale des exécutions au fil du temps. Les 10 dernières exécutions de tous les ensembles de règles sont affichées par défaut. Pour filtrer par ensemble de règles, sélectionnez celui que vous souhaitez dans la liste déroulante. S'il y a moins de 10 exécutions, toutes les exécutions terminées disponibles sont affichées.
4. Dans la table Qualité des données, chaque ensemble de règles avec sa dernière exécution (le cas échéant) est affiché, ainsi que le score. En développant l'ensemble de règles, vous affichez les règles qu'il contient, ainsi que les résultats de l'exécution.

Pour voir la dernière exécution sur un ensemble de règles en particulier

1. Dans la console AWS Glue, choisissez Tables dans le volet de navigation. Choisissez ensuite la table pour laquelle vous souhaitez exécuter une tâche liée à la qualité des données.

2. Choisissez l'onglet Qualité des données.
3. Dans le tableau Qualité des données, choisissez un ensemble de règles spécifique.
4. Sur la page Détails de l'ensemble de règles, choisissez l'onglet Historique des exécutions.

Toutes les exécutions d'évaluation pour cet ensemble de règles particulier sont répertoriées dans la table de cet onglet. Vous pouvez consulter l'historique des scores et le statut des exécutions.

5. Pour obtenir plus d'informations sur une exécution en particulier, choisissez l'ID d'exécution pour accéder à la page Détails de l'exécution d'évaluation. Sur cette page, vous pouvez consulter des informations sur l'exécution et plus de détails sur le statut des résultats des règles individuelles.

Rubriques en relation

- [Référence du type de règle DQDL](#)
- [Référence DQDL \(Data Quality Definition Language\)](#)

Évaluation de la qualité des données avec AWS Glue Studio

AWS Glue Data Quality évalue et contrôle la qualité de vos données en fonction de règles que vous définissez. Ainsi, les données qui nécessitent une action sont identifiables facilement. Dans AWS Glue Studio, vous pouvez ajouter des nœuds de qualité des données à votre tâche visuelle afin d'appliquer des règles de qualité des données aux tableaux de votre catalogue de données. Vous pouvez ensuite contrôler et évaluer les modifications apportées à vos jeux de données tout au long de leur évolution. Pour un aperçu de la manière d'utiliser la qualité des données de AWS Glue dans AWS Glue Studio, regardez la vidéo suivante.

Voici les étapes générales décrivant l'utilisation d'AWS Glue Data Quality :

1. Création de règles de qualité des données : créez des règles de qualité des données à l'aide du générateur de règles DQDL en choisissant les ensembles de règles intégrés que vous configurez.
2. Configuration d'une tâche de qualité des données : définissez des actions en fonction des résultats relatifs à la qualité des données et des options de sortie.
3. Enregistrement et exécution d'une tâche de qualité des données : créez et exécutez une tâche. L'enregistrement de la tâche inclut les ensembles de règles que vous avez créés pour la tâche.
4. Contrôle et vérification des résultats relatifs à la qualité des données : vérifiez les résultats une fois la tâche terminée. Vous pouvez également planifier l'exécution de la tâche à une date future.

Avantages

Les analystes, les ingénieurs et les spécialistes des données peuvent utiliser le nœud Évaluer la qualité des données dans AWS Glue Studio pour analyser, configurer, surveiller et améliorer la qualité des données dans l'éditeur de tâches visuel. L'utilisation d'un nœud de qualité des données présente les avantages suivants :

- Détection des problèmes de qualité des données : la création de règles qui vérifient les caractéristiques de vos jeux de données permet de détecter les problèmes.
- Démarrage simplifié : vous pouvez commencer par utiliser des règles et des actions prédéfinies.
- Intégration étroite : vous pouvez utiliser des nœuds de qualité des données dans AWS Glue Studio, car la qualité des données de AWS Glue s'exécute au-dessus de AWS Glue Data Catalog.

Évaluation de la qualité des données pour les tâches ETL dans AWS Glue Studio

Dans ce didacticiel, vous ferez vos premiers pas avec la qualité des données de AWS Glue dans AWS Glue Studio. Vous allez apprendre comment :

- Créer des règles à l'aide du générateur de règles DQDL (Data Quality Definition Language).
- Spécifier les actions relatives à la qualité des données, les données de sortie et l'emplacement de sortie des résultats en matière de qualité des données.
- Vérifier les résultats en matière de qualité des données.

Pour vous entraîner avec un exemple, consultez le billet de blog [Getting started with AWS Glue Data Quality for ETL pipelines](#).

Étape 1 : Ajout du nœud de transformation Évaluer la qualité des données à la tâche visuelle

À ce stade, vous ajoutez le nœud d'évaluation de la qualité des données à l'éditeur de tâches visuel.

Pour ajouter le nœud de qualité des données, procédez comme suit :

1. Dans la console AWS Glue Studio, choisissez Visual avec une source et une cible dans la section Create job, puis choisissez Create.

2. Choisissez le nœud auquel vous souhaitez appliquer la transformation de qualité des données. Il s'agit généralement d'un nœud de transformation ou d'une source de données.
3. Ouvrez le panneau de ressources sur la gauche en cliquant sur l'icône « + ». Recherchez ensuite Évaluer la qualité des données dans la barre de recherche, puis sélectionner Évaluer la qualité des données dans les résultats de la recherche.
4. L'éditeur de tâches visuel affiche la ramification du nœud de transformation Évaluer la qualité des données à partir du nœud que vous avez sélectionné. Sur le côté droit de la console, l'onglet Transform (Transformer) s'ouvre automatiquement. Si vous devez modifier le nœud parent, choisissez l'onglet Propriétés du nœud, puis choisissez le nœud parent dans le menu déroulant.

Lorsque vous choisissez un nouveau nœud parent, une nouvelle connexion est établie entre le nœud parent et le nœud Évaluer la qualité des données (Évaluer la qualité des données). Supprimez tous les nœuds parents indésirables. Un seul nœud parent peut être connecté à un nœud Évaluer la qualité des données.

5. La transformation Évaluer la qualité des données prend en charge plusieurs parents afin que vous puissiez valider les règles de qualité des données sur plusieurs jeux de données. Les règles qui prennent en charge plusieurs ensembles de données incluent ReferentialIntegrity, DatasetMatch, SchemaMatch, RowCountMatch, et AggregateMatch.

Lorsque vous ajoutez plusieurs entrées à la transformation Évaluer la qualité des données, vous devez sélectionner votre entrée « principale ». Votre entrée principale est le jeu de données dont vous souhaitez valider la qualité des données. Tous les autres nœuds ou entrées sont traités comme des références.

Vous pouvez utiliser la transformation Évaluer la qualité des données pour identifier les enregistrements spécifiques qui ont échoué aux contrôles de qualité des données. Nous vous recommandons de choisir votre jeu de données principal, car de nouvelles colonnes qui signalent les enregistrements défectueux sont ajoutées au jeu de données principal.

6. Vous pouvez spécifier des alias pour les sources de données d'entrée. Les alias constituent un autre moyen de référencer la source d'entrée lorsque vous utilisez la ReferentialIntegrity règle. Comme une seule source de données peut être désignée comme source principale, chaque source de données supplémentaire que vous ajoutez nécessite un alias.

Dans l'exemple suivant, la ReferentialIntegrity règle spécifie la source de données d'entrée par le nom d'alias et effectue une one-to-one comparaison avec la source de données principale.

```
Rules = [
```



```
ReferentialIntegrity "Aliasname.name" = 1  
]
```

Étape 2 : Création d'une règle à l'aide de DQDL

Cette étape permet de créer une règle avec DQDL. Dans le cadre de ce didacticiel, vous créez une règle unique à l'aide du type de règle Exhaustivité. Ce type de règle compare le pourcentage de valeurs complètes (non nulles) d'une colonne à une expression donnée. Pour plus d'informations sur l'utilisation de DQDL, consultez [DQDL](#).

1. Dans l'onglet Transformer, ajoutez un Type de règle en cliquant sur le bouton Insérer. Le type de règle est alors ajouté à l'éditeur de règles dans lequel vous pouvez saisir les paramètres de la règle.

Note

Lorsque vous modifiez des règles, assurez-vous qu'elles se trouvent entre crochets et qu'elles sont séparées par des virgules. Par exemple, une expression de règle complète a la syntaxe suivante :

```
Rules= [  
    Completeness "year">0.8, Completeness "month">0.8  
]
```

Cet exemple spécifie le paramètre d'exhaustivité pour les colonnes « année » et « mois ». Pour que la règle soit transmise, ces colonnes doivent être « complètes » à plus de 80 % ou contenir des données dans plus de 80 % des instances pour chaque colonne respective.

Dans cet exemple, recherchez et insérez le type de règle Completeness (Exhaustivité). Le type de règle est alors ajouté à l'éditeur de règles. La syntaxe de ce type de règle est la suivante : `Completeness <COL_NAME> <EXPRESSION>`.

Une expression doit être fournie comme paramètre pour la plupart des types de règles afin de créer une réponse booléenne. Pour plus d'informations sur les expressions DQDL prises en charge, consultez [DQDL expressions](#). Vous ajoutez ensuite le nom de la colonne.

2. Dans le générateur de règles DQDL, choisissez l'onglet Schéma. Trouvez le nom de la colonne dans le schéma d'entrée à l'aide de la barre de recherche. Le schéma d'entrée affiche le nom de la colonne et le type de données.
3. Dans l'éditeur de règles, cliquez à droite du type de règle pour insérer le curseur au point d'insertion de la colonne. Vous pouvez également saisir le nom de la colonne dans la règle.

Par exemple, dans la liste des colonnes de la liste des schémas d'entrée, cliquez sur le bouton Insérer à côté de la colonne (ici, il s'agit de année). La colonne est alors ajoutée à la règle.

4. Ajoutez ensuite une expression pour évaluer la règle dans l'éditeur de règles. Comme le type de règle Exhaustivité vérifie le pourcentage de valeurs complètes (non nulles) dans une colonne par rapport à une expression donnée, saisissez une expression telle que `> 0.8`. Cette règle vérifie si la colonne contient plus de 80 % de valeurs complètes (non nulles).

Étape 3 : Configuration des résultats de la qualité des données

Une fois les règles de qualité des données créées, vous pouvez sélectionner des options supplémentaires pour spécifier la sortie du nœud de qualité des données.

1. Dans Data quality transform output (Sortie de transformation de la qualité des données), choisissez l'une des options suivantes :
 - Données d'origine : permet de fournir les données d'entrée d'origine. Lorsque vous choisissez cette option, un nouveau nœud enfant « rowLevelOutcomes » est ajouté à la tâche. Le schéma correspond au schéma du jeu de données principal qui a été transmis en tant qu'entrée à la transformation. Cette option est utile si vous souhaitez simplement transmettre les données et faire échouer la tâche en cas de problèmes de qualité.

Un autre cas d'utilisation est celui où vous souhaitez détecter des enregistrements défectueux qui ont échoué aux contrôles de qualité des données. Pour détecter les enregistrements défectueux, choisissez l'option Ajouter de nouvelles colonnes pour indiquer les erreurs de qualité des données. Cette action ajoute quatre nouvelles colonnes au schéma de la transformation « rowLevelOutcomes ».

- `DataQualityRulesPass`(tableau de chaînes) — Fournit un tableau de règles ayant passé avec succès les contrôles de qualité des données.
 - `DataQualityRulesFail`(tableau de chaînes) — Fournit un tableau de règles ayant échoué aux contrôles de qualité des données.
 - `DataQualityRulesSkip`(tableau de chaînes) — Fournit un tableau de règles qui ont été ignorées. Les règles suivantes ne peuvent pas identifier les enregistrements d'erreur, car elles sont appliquées au niveau du jeu de données.
 - `AggregateMatch`
 - `ColumnCount`
 - `ColumnExists`
 - `ColumnNamesMatchPattern`
 - `CustomSql`
 - `RowCount`
 - `RowCountMatch`
 - `StandardDeviation`
 - `Mean`
 - `ColumnCorrelation`
 - `DataQualityEvaluationResult`— Indique le statut « Réussi » ou « Échec » au niveau de la ligne. Notez que vos résultats globaux peuvent être un ÉCHEC, mais que certains enregistrements peuvent avoir réussi. Par exemple, il se peut que la `RowCount` règle ait échoué, mais que toutes les autres règles aient réussi. Dans de tels cas, l'état de ce champ est « Réussi ».
2. Résultats relatifs à la qualité des données : permet de fournir les règles configurées et leur état de réussite ou d'échec. Cette option est utile si vous souhaitez écrire vos résultats dans Amazon S3 ou dans d'autres bases de données.
 3. Paramètres de sortie de qualité des données (facultatif) : choisissez Paramètres de sortie de qualité des données pour afficher le champ Emplacement des résultats relatifs à la qualité des données. Choisissez ensuite Parcourir pour rechercher un emplacement Amazon S3 à définir comme cible de sortie relative à la qualité des données.

Étape 4 : Configuration des actions relatives à la qualité des données

Vous pouvez utiliser des actions pour publier des métriques CloudWatch ou pour arrêter des tâches en fonction de critères spécifiques. Les actions sont disponibles uniquement lorsqu'une règle est créée. Lorsque vous choisissez cette option, les mêmes métriques sont également publiées dans Amazon EventBridge. Vous pouvez utiliser ces options pour [créer des alertes de notification](#).

- En cas d'échec d'un ensemble de règles : vous pouvez choisir la procédure à suivre en cas d'échec d'un ensemble de règles pendant l'exécution de la tâche. Si vous souhaitez que la tâche échoue en cas d'échec de la qualité des données, choisissez le moment où la tâche doit échouer en sélectionnant l'une des options suivantes. Par défaut, cette action n'est pas sélectionnée et la tâche termine son exécution même si les règles de qualité des données échouent.
- Aucun : si vous choisissez Aucun (par défaut), la tâche n'échoue pas et continue de s'exécuter malgré les échecs de l'ensemble de règles.
- Échec de la tâche après le chargement des données sur la cible : la tâche échoue et aucune donnée n'est enregistrée. Pour enregistrer les résultats, choisissez un emplacement Amazon S3 où les résultats relatifs à la qualité des données seront enregistrés.
- Échec de la tâche sans chargement vers les données cibles : cette option échoue immédiatement en cas d'erreur de qualité des données. Aucune cible de données n'est chargée, y compris les résultats de la transformation de la qualité des données.

Étape 5 : Consultation des résultats relatifs à la qualité des données

Une fois la tâche exécutée, choisissez l'onglet Qualité des données pour consulter les résultats relatifs à la qualité des données.

1. Pour chaque tâche exécutée, vous pouvez consulter les résultats relatifs à la qualité des données. Chaque nœud affiche un état de qualité des données et des informations détaillées. Choisissez un nœud pour afficher toutes les règles et l'état de chaque règle.
2. Choisissez Télécharger les résultats pour télécharger un fichier CSV contenant des informations sur l'exécution de la tâche et les résultats relatifs à la qualité des données.
3. Si plusieurs tâches exécutées sont associées à des résultats relatifs à la qualité des données, vous pouvez filtrer les résultats par date et par plage horaire. Choisissez Filtrer par plage de dates et d'heures pour agrandir la fenêtre de filtre.

4. Choisissez une plage relative ou une plage absolue. Pour les plages absolues, sélectionnez une date et entrez des valeurs pour l'heure de début et l'heure de fin à l'aide du calendrier. Lorsque vous avez terminé, choisissez Appliquer.

Qualité automatique des données

Lorsque vous créez une tâche AWS Glue ETL avec Amazon S3 comme cible, AWS Glue ETL active automatiquement une règle de qualité des données qui vérifie si les données chargées comportent au moins une colonne. Cette règle est conçue pour garantir que les données chargées ne sont pas vides ou endommagées. Toutefois, si cette règle échoue, la tâche n'échouera pas ; au contraire, vous remarquerez une réduction de votre score de qualité des données. En outre, la détection des anomalies est activée par défaut, ce qui permet de surveiller le nombre de colonnes des données. En cas de variations ou d'anomalies dans le nombre de colonnes, AWS Glue ETL vous informera de ces anomalies. Cette fonctionnalité vous aide à identifier les problèmes potentiels liés aux données et à prendre les mesures appropriées. Pour consulter la règle de qualité des données et sa configuration, vous pouvez cliquer sur la cible Amazon S3 dans votre tâche AWS Glue ETL. La configuration de la règle sera affichée, comme le montre la capture d'écran fournie.

The screenshot displays the AWS Glue console interface for configuring a data quality rule. The main workspace shows a workflow with three nodes: 'Data source - S3 bucket Amazon S3', 'Transform - Aggregate Aggregate', and 'Data target - S3 bucket Amazon S3'. The 'Data target' node is selected, and the right-hand pane shows its configuration. Under 'S3 Target Location', the 'S3 Target Location' is set to 's3://bucket/prefix/object'. The 'Data Catalog update options' section shows 'Do not update the Data Catalog' selected. The 'Partition keys - optional' section has an 'Add a partition key' button. The 'Check data quality' section is checked, with a note to 'Evaluate data quality before loading data to target. Enable this to check your data for common issues to ensure the data being loaded to target is complete.' Below this, the 'Data quality rules' section shows a rule 'Column count is always greater than 0'. The 'Data quality actions' section shows 'Continue processing when bad data is detected'. At the bottom, there is a button to 'Edit data quality configuration'.

Vous pouvez ajouter des règles de qualité des données supplémentaires en sélectionnant Modifier la configuration de la qualité des données.

Métriques agrégées

Vous pouvez avoir besoin de statistiques agrégées telles que le nombre d'enregistrements réussis, échoués ou ignorés au niveau des règles ou des ensembles de règles pour créer des tableaux de bord. Afin d'obtenir les métriques agrégées et les métriques de règles pour chaque règle,

activez d'abord les métriques agrégées en ajoutant l'`publishAggregatedMetrics` option à votre `EvaluateDataQuality` fonction.

Les options possibles pour `additional_options` `publishAggregatedMetrics` sont `ENABLED` et `DISABLED`. À titre d'exemple :

```
EvaluateDataQualityMultiframe = EvaluateDataQuality().process_rows(  
    frame=medicare_dyf,  
    ruleset=EvaluateDataQuality_ruleset,  
    publishing_options={  
        "dataQualityEvaluationContext": "EvaluateDataQualityMultiframe",  
        "enableDataQualityCloudWatchMetrics": False,  
        "enableDataQualityResultsPublishing": False,  
    },  
    additional_options={"publishAggregatedMetrics.status": "ENABLED"},  
)
```

S'il n'est pas spécifié, `publishAggregatedMetrics.status` c'est `DISABLED` par défaut et les `RuleMetrics` et les métriques agrégées seront désormais calculées. Cette fonctionnalité est actuellement prise en charge dans les sessions AWS Glue Interactive et dans les jobs Glue ETL. Cela n'est pas pris en charge dans Glue Catalog Data Quality APIs.

Récupération des résultats des métriques agrégées

Quand `additionalOptions` `"publishAggregatedMetrics.status": "ENABLED"`, vous pouvez obtenir les résultats à deux endroits :

1. `AggregatedMetricset` `RuleMetrics` sont renvoyés par le biais du `GetDataQualityResult()` lorsque vous fournissez le `resultId` lieu `AggregatedMetrics` et `RuleMetrics` incluent :

Métriques agrégées :

- Nombre total de lignes traitées
- Nombre total de lignes transmises
- Nombre total de lignes ayant échoué
- Nombre total de règles traitées
- Nombre total de règles adoptées
- Nombre total de règles ayant échoué

```

% aws --region us-east-1 glue get-data-quality-result --result-id "dqresult-09655f0234b3e3d129381bd162d0347ed25d1c05"
{
  "ResultId": "dqresult-09655f0234b3e3d129381bd162d0347ed25d1c05",
  "ProfileId": "dqprofile-",
  "Score": 0.6666666666666666,
  "RulesetName": "EvaluateDataQuality_node1741974822533",
  "EvaluationContext": "EvaluateDataQuality_node1741974822533",
  "StartedOn": 1750687515.374,
  "CompletedOn": 1750687537.485,
  "JobName": "aggregatedmetrics_test",
  "JobRunId": "jr-",
  "RuleResults": [
    {
      "Name": "Rule_1",
      "Description": "IsUnique \"customer_identifie\"",
      "Result": "PASS",
      "EvaluatedMetrics": {
        "Column.customer_identifie.Uniqueness": 1.0
      },
      "EvaluatedRule": "IsUnique \"customer_identifie\"",
      "RuleMetrics": {
        "rows_passed": 10.0,
        "rows_failed": 0.0,
        "rows_skipped": 0.0,
        "total_rows": 10.0
      }
    },
    {
      "Name": "Rule_2",
      "Description": "RowCount > 10",
      "EvaluationMessage": "Value: 10 does not meet the constraint requirement!",
      "Result": "FAIL",
      "EvaluatedMetrics": {
        "Dataset.*.RowCount": 10.0
      },
      "EvaluatedRule": "RowCount > 10",
      "RuleMetrics": {
        "rows_passed": 0.0,
        "rows_failed": 0.0,
        "rows_skipped": 10.0,
        "total_rows": 10.0
      }
    },
    {
      "Name": "Rule_3",
      "Description": "Completeness \"customer_identifie\" > 0.5",
      "Result": "PASS",
      "EvaluatedMetrics": {
        "Column.customer_identifie.Completeness": 1.0
      },
      "EvaluatedRule": "Completeness \"customer_identifie\" > 0.5",
      "RuleMetrics": {
        "rows_passed": 10.0,
        "rows_failed": 0.0,
        "rows_skipped": 0.0,
        "total_rows": 10.0
      }
    }
  ],
  "AggregatedMetrics": {
    "TotalRowsProcessed": 10.0,
    "TotalRowsPassed": 10.0,
    "TotalRowsFailed": 0.0,
    "TotalRulesProcessed": 3.0,
    "TotalRulesPassed": 2.0,
    "TotalRulesFailed": 1.0
  }
}

```

En outre, au niveau des règles, les métriques suivantes sont fournies :

Métriques des règles :

- Lignes transmises
- Les lignes ont échoué
- Ligne ignorée
- Nombre total de lignes traitées

2. `AggregatedMetrics` est renvoyé sous forme de trame de données supplémentaire et la trame de `RuleOutcomes` données est augmentée pour être incluse `RuleMetrics`.

Exemple de mise en œuvre

L'exemple suivant montre comment implémenter des métriques agrégées dans Scala :

```
// Script generated for node Evaluate Data Quality
val EvaluateDataQuality_node1741974822533_ruleset = ""
  # Example rules: Completeness "colA" between 0.4 and 0.8, ColumnCount > 10
  Rules = [
    IsUnique "customer_identifiant",
    RowCount > 10,
    Completeness "customer_identifiant" > 0.5
  ]
""

val EvaluateDataQuality_node1741974822533 =
  EvaluateDataQuality.processRows(frame=ChangeSchema_node1742850392012,
    ruleset=EvaluateDataQuality_node1741974822533_ruleset,
    publishingOptions=JsonOptions("""{"dataQualityEvaluationContext":
  "EvaluateDataQuality_node1741974822533", "enableDataQualityCloudWatchMetrics":
  "true", "enableDataQualityResultsPublishing": "true"}"""),
    additionalOptions=JsonOptions("""{"compositeRuleEvaluation.method":"ROW","observations.scope":
  "publishAggregatedMetrics.status": "ENABLED"}"""))

println("-----ROW LEVEL
  OUTCOMES-----")
val rowLevelOutcomes_node = EvaluateDataQuality_node1741974822533("rowLevelOutcomes")

rowLevelOutcomes_node.show(10)

println("-----RULE LEVEL
  OUTCOMES-----")

val ruleOutcomes_node = EvaluateDataQuality_node1741974822533("ruleOutcomes")

ruleOutcomes_node.show()

println("-----AGGREGATED
  METRICS-----")

val aggregatedMetrics_node = EvaluateDataQuality_node1741974822533("aggregatedMetrics")
```



```
aggregatedMetrics_node.show()
```

Exemples de résultats

Les résultats sont renvoyés comme suit :

```
{
  "Rule": "IsUnique \"customer_identifier\"",
  "Outcome": "Passed",
  "FailureReason": null,
  "EvaluatedMetrics": {
    "Column.customer_identifier.Uniqueness": 1
  },
  "EvaluatedRule": "IsUnique \"customer_identifier\"",
  "PassedCount": 10,
  "FailedCount": 0,
  "SkippedCount": 0,
  "TotalCount": 10
}
{
  "Rule": "RowCount > 10",
  "Outcome": "Failed",
  "FailureReason": "Value: 10 does not meet the constraint requirement!",
  "EvaluatedMetrics": {
    "Dataset.*.RowCount": 10
  },
  "EvaluatedRule": "RowCount > 10",
  "PassedCount": 0,
  "FailedCount": 0,
  "SkippedCount": 10,
  "TotalCount": 10
}
{
  "Rule": "Completeness \"customer_identifier\" > 0.5",
  "Outcome": "Passed",
  "FailureReason": null,
  "EvaluatedMetrics": {
    "Column.customer_identifier.Completeness": 1
  },
  "EvaluatedRule": "Completeness \"customer_identifier\" > 0.5",
  "PassedCount": 10,
  "FailedCount": 0,
  "SkippedCount": 0,
```

```
"TotalCount": 10  
}
```

Les métriques agrégées sont les suivantes :

```
{ "TotalRowsProcessed": 10, "PassedRows": 10, "FailedRows": 0, "TotalRulesProcessed":  
  3, "RulesPassed": 2, "RulesFailed": 1 }
```

Générateur de règles de qualité des données

Avec le générateur de règles DQDL (Data Quality Definition Language), vous pouvez créer des règles de qualité pour évaluer vos données. Commencez par sélectionner un type de règle, puis spécifiez les paramètres dans l'éditeur de règles. L'éditeur de règles affiche également les erreurs et les avertissements éventuels lors de la création de règles.

Le [guide DQDL](#) documente de manière exhaustive la création de règles à l'aide de la syntaxe DQDL, les types de règles intégrées et des exemples.

Nœud Évaluer la qualité des données

En utilisant le nœud de transformation Évaluer la qualité des données et le générateur de règles DQDL, vous pouvez étendre l'espace de travail.

- Pour afficher l'onglet Transformer en mode plein écran, cliquez sur l'icône d'expansion dans le coin supérieur droit du panneau de détails du nœud.
- Pour développer l'éditeur de règles DQDL, cliquez sur l'icône << pour développer l'éditeur de règles et réduire les onglets Types de règles et Schéma.

The screenshot shows the AWS Glue Studio interface for configuring a data quality job. The main canvas displays a workflow diagram where two data sources, 'employees' and 'customers', feed into a central 'Transform - Evaluate Data Quality' node. This node then outputs to two 'Transform - SelectFrom...' nodes, which feed into two data targets: 'Amazon S3' and 'AWS Glue Data Catalog'.

The right-hand pane shows the configuration for the 'Evaluate Data Quality' node. It includes sections for 'Node parents', 'Aliases for referenced data sources', 'Input sources', and a 'Helper' section with 'Rule types' and 'Schema'. The 'Rules' section shows a custom SQL rule for Referential Integrity.

```

1 Rules = [
2   ReferentialIntegrity "employeeNumber" "customers
3     salesRepEmployeeNumber" between 0.6 and 0.7,
4   RowCount > 1000,
5   CustomSql "select count(*) from primary" between 10 and 200
6 ]

```

Composants

26 types de règles sont intégrés AWS Glue Studio. Chaque type de règle comporte une description et des exemples de la manière dont ils peuvent être utilisés.

Types de règles de qualité des données

AWS Glue Studio fournit des types de règles intégrés pour faciliter la création d'une règle. Pour plus d'informations sur les types de règles, consultez la [Référence du type de règle DQDL](#).

Schema

L'onglet Schema (Schéma) affiche les noms des colonnes et le type de données du nœud parent. Les schémas de plusieurs nœuds sont affichés. Vous pouvez consulter le schéma d'entrée, effectuer une recherche par nom de colonne et insérer la colonne dans l'éditeur de règles.

Node properties | **Transform** | **Output schema** | **Data preview** 

Evaluate data quality [Info](#)
Evaluate data quality by defining your data quality rules and actions

Data quality rules [Info](#)
Add rules using DQDL (Data Quality Definition Language)

DQDL rule builder <<

Rule types (18) **Schema**

▼ Input schema

year
int

+

month
int

+

day
int

+

fl_date
string

+

1 ▾
2
3

Rules= [
 Completeness"year">0.8
]

Ln 1, Col 1

Errors: 0

Warnings: 0

Éditeur de règles

L'éditeur de règles est un éditeur de texte permettant d'écrire et de modifier des règles. Si vous sélectionnez un type de règle dans le générateur de règles DQDL, il est ajouté à l'éditeur de règles. Vous pouvez ensuite spécifier des paramètres, ajouter des règles et modifier des règles selon vos besoins en modifiant le texte. AWS Glue Studio valide les règles dans l'éditeur de règles et affiche les erreurs et les avertissements éventuels.

Erreurs et avertissements

Si une règle n'est pas conforme à la syntaxe des règles DQDL, l'éditeur de règles affiche plusieurs indicateurs d'erreur visuels :

- L'éditeur de règles affiche une icône d'erreur de couleur rouge sur la ligne contenant l'erreur.
- L'éditeur de règles affiche le nombre d'erreurs à côté de l'icône d'erreur rouge.
- Lorsque vous cliquez sur la ligne contenant l'erreur, des descriptions et l'emplacement de l'erreur (ligne et colonne) s'affichent en bas de l'éditeur de règles.

Node properties | **Transform** | **Output schema** | **Data preview** 

Evaluate data quality [Info](#)
Evaluate data quality by defining your data quality rules and actions

Data quality rules [Info](#)
Add rules using DQDL (Data Quality Definition Language)

DQDL rule builder <<

Rule types (18) | **Schema**

ColumnCorrelation
column rule
▶ **Description, examples**

ColumnExists
column rule
▶ **Description, examples**

ColumnLength
column rule
▶ **Description, examples**

⊗ 1 **ColumnCorrelation**

Ln 1, Col 18

⊗ 1

 ⚠ 0 

Ln 1, Col 1 h is null 

Actions relatives à la qualité des données

Par défaut, cette action n'est pas sélectionnée et la tâche s'exécute même si les règles de qualité des données ne sont pas respectées.

Générateur de règles de qualité des données

2036

Choisissez l'une des actions suivantes. Vous pouvez utiliser des actions pour publier les résultats des tâches CloudWatch ou les arrêter en fonction de critères spécifiques. Les actions sont disponibles uniquement lorsqu'une règle est créée.

- Publier les résultats sur CloudWatch : lorsque vous exécutez une tâche, ajoutez-les à CloudWatch.
- Échec d'une tâche en cas de problème de qualité des données : si les règles de qualité des données ne sont pas respectées, la tâche échoue.

Sortie de transformation de la qualité des données

- Données d'origine : permet de fournir les données d'entrée d'origine. Cette option est particulièrement utile pour interrompre la tâche en cas de détection de problèmes de qualité.
- Métriques de qualité des données : permet de générer les règles configurées et leur état de réussite ou d'échec. Cette option est utile si vous souhaitez effectuer une action personnalisée.

Paramètres de sortie de qualité des données

Définissez l'emplacement des résultats relatifs à la qualité des données en spécifiant l'emplacement Amazon S3 comme cible de sortie.

Configuration de la détection des anomalies dans les jobs AWS Glue ETL

Pour commencer à détecter les anomalies dans AWS Glue Studio, ouvrez une tâche AWS Glue Studio et cliquez sur Evaluate Data Quality Transform.

En activant cette fonctionnalité, AWS Glue Data Quality analysera vos données au fil du temps afin de détecter les anomalies. Il fournit des statistiques et des observations précieuses sur vos données, ce qui vous permet de prendre des mesures en cas d'anomalie identifiée.

Consultez la documentation sur la [détection des anomalies](#) pour comprendre le fonctionnement interne de cette fonctionnalité.

Activation de la détection des anomalies

Pour activer la détection des anomalies dans AWS Glue Studio:

1. Choisissez le nœud Qualité des données dans votre tâche, puis cliquez sur l'onglet Détection des anomalies. Activez l'option Activer la détection des anomalies.

Ruleset editor

Anomaly detection [New](#)

☒ **Enable anomaly detection** [Info](#)
Anomaly detection leverages machine learning algorithms to analyze statistics collected by rules and analyzers, allowing us to detect unanticipated and hidden data quality issues. Enable detect anomalies to generate observations on your data during a job run.

Anomaly detection scope (0)
Scope of data statistics configured to be analyzed for anomalies.


Actions ▼

Add analyzer

Scope of statistics	Scope of data	Source
No anomaly detection configuration No configuration to display.		

Summary
0 data quality rule(s). 0 analyzers.
Anomaly detection enabled on data statistics from rules and analyzers.

2. Définissez les données à surveiller pour détecter les anomalies en choisissant Ajouter un analyseur. Vous pouvez remplir deux champs : Statistiques et Données.
 - Les statistiques sont des informations sur la forme et les autres propriétés de vos données. Vous pouvez choisir une ou plusieurs statistiques à la fois, ou choisir Toutes les statistiques. Les statistiques incluent : l'exhaustivité, l'unicité, la moyenne, la somme StandardDeviation, l'entropie DistinctValuesCount, UniqueValueRatio etc. Reportez-vous à la documentation [des analyseurs](#) pour plus de détails.
 - Les données sont les colonnes de votre ensemble de données. Vous pouvez choisir toutes les colonnes ou des colonnes individuelles.



3. Choisissez Ajouter une zone de détection d'anomalies pour enregistrer vos modifications. Une fois que vous avez ajouté des analyseurs, vous pouvez les voir dans la section Champ de détection des anomalies.

Vous pouvez également utiliser le menu Actions pour modifier vos analyseurs, ou choisir l'onglet Éditeur de jeu de règles et modifier l'analyseur directement dans le bloc-notes de l'éditeur de jeu de règles. Vous verrez les analyseurs que vous avez enregistrés selon les règles que vous avez créées.

```
Rules = [

]

Analyzers = [
    Completeness "id"
]
```

Une fois l'ensemble de règles et les analyseurs mis à jour configurés, AWS Glue Data Quality surveille en permanence les flux de données entrants. Il peut signaler des anomalies potentielles par

le biais d'alertes ou d'arrêts de travail, en fonction de vos paramètres. Cette surveillance proactive permet de garantir la qualité et l'intégrité des données dans l'ensemble de vos pipelines de données.


Dans la section suivante, vous apprendrez comment surveiller efficacement les anomalies identifiées par le système. Vous apprendrez également à consulter et à analyser les statistiques de données recueillies par AWS Glue Data Quality. En outre, vous apprendrez comment fournir des commentaires au modèle d'apprentissage automatique qui alimente la fonction de détection des anomalies. Cette boucle de rétroaction est essentielle pour améliorer la précision du modèle et garantir qu'il peut détecter efficacement les anomalies conformes aux exigences spécifiques de votre entreprise et à vos modèles de données.

Visualisation des scores de qualité des données et des anomalies

Dans cette section, nous allons explorer le tableau de bord de qualité des données et les différentes fonctionnalités qu'il fournit.

Visualisez et comprenez les indicateurs et tendances de qualité des données de haut niveau


Une fois que votre travail est réussi, cliquez sur l'onglet Qualité des données pour afficher les scores de qualité des données et les anomalies.



Les composants suivants de l'onglet Qualité des données fournissent des informations utiles.

1. Cliquez sur l'onglet Qualité des données pour afficher les indicateurs de qualité des données.
2. Sélectionnez un identifiant d'exécution de tâche spécifique pour afficher le score de qualité des données.
3. Ce volet affiche trois informations importantes. Vous pouvez choisir chacune d'elles pour accéder à des tables spécifiques afin de visualiser les anomalies, les statistiques de données ou les règles.
 - Score de qualité des données lorsque les règles sont configurées.
 - Nombre de statistiques recueillies par Rules and Analyzers.
 - Nombre total d'anomalies détectées.
4. Ce graphique de tendance montre l'évolution de la qualité des données au fil du temps. Vous pouvez survoler la tendance et atteindre un moment précis où les scores de qualité des données se sont détériorés.
5. L'évolution des anomalies au fil du temps vous indiquera le nombre d'anomalies détectées au fil du temps.
6. Onglets :
 - L'onglet Règles est l'onglet par défaut qui affiche la liste de toutes les règles et de leur statut. Les règles évaluées sont utiles dans le cas de règles dynamiques pour afficher la valeur réelle à laquelle la règle a été évaluée.
 - L'onglet Statistiques répertorie toutes les statistiques, vous permettant de visualiser les métriques et les tendances au fil du temps.
 - L'onglet Anomalies affiche la liste des anomalies détectées.

Visualisation des anomalies et apprentissage de l'algorithme de détection des anomalies



Appels pour l'image ci-dessus :

1. Lorsque des anomalies sont détectées, cliquez sur l'anomalie ou sélectionnez l'onglet Anomalies
2. AWS Glue Data Quality fournit une explication détaillée de l'anomalie, de la valeur réelle et de la plage prévue
3. AWS Glue Data Quality indique une courbe de tendance. Il a la valeur réelle, une tendance dérivée basée sur les valeurs réelles (ligne rouge), la limite supérieure et la limite inférieure
4. AWS Glue Data Quality recommande des règles de qualité des données qui peuvent être utilisées pour capturer les modèles futurs. Vous pouvez copier toutes les règles qui vous sont recommandées et les appliquer à votre nœud de qualité des données pour capturer efficacement ces modèles.

5. Vous pouvez fournir des entrées au modèle d'apprentissage automatique (ML) pour exclure les valeurs anormales, afin de garantir que les futures exécutions détectent les anomalies avec précision. Si vous n'excluez pas explicitement les anomalies, AWS Glue Data Quality les prendra automatiquement en compte dans le modèle pour les prévisions futures. Il est important de noter que seule la dernière exécution reflétera les entrées du modèle que vous fournissez. Par exemple, si vous revenez en arrière et que vous avez exclu des points anormaux lors de quelques essais précédents, le modèle ne reflétera pas ces modifications à moins que vous ne consultiez et ne mettiez à jour les entrées du modèle lors de la dernière exécution. Le modèle continuera à utiliser les entrées fournies précédemment jusqu'à ce que vous apportiez les ajustements nécessaires lors de la dernière exécution. En gérant activement l'exclusion des valeurs anormales, vous pouvez affiner la compréhension par le modèle ML de ce qui constitue une anomalie par rapport à vos modèles de données et à vos exigences spécifiques, ce qui permet une détection plus précise des anomalies au fil du temps.

Afficher les statistiques des données au fil du temps et fournir des informations de formation

Parfois, vous souhaitez peut-être consulter les statistiques ou les profils de données et voir comment ils progressent au fil du temps. Pour ce faire, choisissez Statistiques ou ouvrez l'onglet Statistiques. Vous pouvez ensuite consulter les dernières statistiques recueillies par AWS Glue Data Quality.

Rules (1)

Statistics (5)

Anomalies (0)

Dataset statistics - new

Info

Name	RowCount	View trends
AnomalyDetection1_node1718976627849	1386	View trends

Column statistics - new

Info

Filter statistics


<

1

>

Name	Maximum	Minimum	DistinctValuesCount	Completeness	View trends
fare_amount	49.92	1.3	-	-	View trends
pulocationid	-	-	20	-	View trends
passenger_count	-	-	-	1	View trends

Cliquez sur Afficher les tendances pour voir l'évolution de chacune des statistiques au fil du temps.



1. Vous pouvez sélectionner la statistique pour une colonne spécifiée
2. Vous pouvez suivre l'évolution des tendances
3. Vous pouvez sélectionner des valeurs anormales et choisir de les exclure ou de les inclure. En fournissant ces informations, l'algorithme exclura ou inclura les points de données anormaux identifiés et réentraînera le modèle. Ce processus de réentraînement garantit une détection précise des anomalies à l'avenir, car le modèle tire les leçons des commentaires que vous avez fournis pour déterminer quelles valeurs doivent être considérées comme anormales ou non.

Grâce à cette boucle de rétroaction, vous pouvez affiner la compréhension par l'algorithme de ce qui constitue une anomalie par rapport à vos modèles de données spécifiques et à vos exigences commerciales. En excluant les valeurs qui ne doivent pas être signalées comme des anomalies, ou en incluant des valeurs qui ont été oubliées, le modèle réentraîné pourra mieux différencier les points de données attendus des points de données réellement anormaux.

Qualité des données pour les tâches ETL dans les blocs-notes AWS Glue Studio

Dans ce didacticiel, vous apprendrez à utiliser la qualité des données deAWS Glue pour les tâches Extraction, transformation et chargement (ETL) dans les blocs-notes AWS Glue Studio.

Vous pouvez utiliser des blocs-notes dans AWS Glue Studio pour modifier des scripts de tâche et afficher le résultat sans avoir à exécuter une tâche complète. Vous pouvez également ajouter du markdown et enregistrer les blocs-notes sous forme de fichiers `.ipynb` et de scripts de tâche. Notez que vous pouvez démarrer un bloc-notes sans installation locale de logiciels ni gestion de serveurs. Lorsque vous êtes satisfait de votre code, vous pouvez utiliser AWS Glue Studio pour convertir facilement votre bloc-notes en une tâche AWS Glue.

L'ensemble de données que vous utilisez dans cet exemple comprend les données de paiement des prestataires de soins médicaux téléchargées à partir de deux ensembles de données Data.cms.gov : « Résumé des fournisseurs de systèmes de paiement potentiels pour les 100 principaux groupes liés au diagnostic - FY2 2011 » et « Données sur les frais d'hospitalisation pour l'exercice 2011 ».

Après le téléchargement des données, nous avons modifié le jeu de données de manière à introduire quelques enregistrements erronés à la fin du fichier. Ce fichier modifié est situé dans un compartiment Amazon S3 public à l'adresse `s3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv`.

Prérequis

- Rôle AWS Glue avec l'autorisation Amazon S3 d'écrire dans votre compartiment Amazon S3 de destination
- Un nouveau bloc-notes (consultez [Getting started with notebooks in AWS Glue Studio](#))

Création d'une tâche ETL dans AWS Glue Studio

Pour créer une tâche ETL

1. Changez la version de la séance pour AWS Glue 3.0.

Pour ce faire, supprimez toutes les cellules de code standard avec le magic suivant et exécutez la cellule. Notez que ce code standard est automatiquement fourni dans la première cellule lorsqu'un nouveau bloc-notes est créé.

```
%glue_version 3.0
```

2. Copiez et collez le code suivant et exécutez-le dans la cellule.

```
import sys
from awsglue.transforms import *
```

```
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
```

3. Dans la cellule suivante, importez la classe `EvaluateDataQuality` qui évalue la qualité des données de AWS Glue.

```
from awsgluedq.transforms import EvaluateDataQuality
```

4. Dans la cellule suivante, lisez les données source à l'aide du fichier `.csv` stocké dans le compartiment public Amazon S3.

```
medicare = spark.read.format(
    "csv").option(
    "header", "true").option(
    "inferSchema", "true").load(
    's3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv')
medicare.printSchema()
```

5. Convertissez les données au format AWS Glue `DynamicFrame`.

```
from awsglue.dynamicframe import DynamicFrame
medicare_dyf = DynamicFrame.fromDF(medicare, glueContext, "medicare_dyf")
```

6. Créez l'ensemble de règles au format DQDL (Data Quality Definition Language).

```
EvaluateDataQuality_ruleset = """
    Rules = [
        ColumnExists "Provider Id",
        IsComplete "Provider Id",
        ColumnValues " Total Discharges " > 15
    ]
    ]
```



```
"""
```

7. Validez le jeu de données par rapport à l'ensemble de règles.

```
EvaluateDataQualityMultiframe = EvaluateDataQuality().process_rows(
    frame=medicare_dyf,
    ruleset=EvaluateDataQuality_ruleset,
    publishing_options={
        "dataQualityEvaluationContext": "EvaluateDataQualityMultiframe",
        "enableDataQualityCloudWatchMetrics": False,
        "enableDataQualityResultsPublishing": False,
    },
    additional_options={"performanceTuning.caching": "CACHE_NOHING"},
)
```

8. Passez en revue les résultats.

```
ruleOutcomes = SelectFromCollection.apply(
    dfc=EvaluateDataQualityMultiframe,
    key="ruleOutcomes",
    transformation_ctx="ruleOutcomes",
)

ruleOutcomes.toDF().show(truncate=False)
```

Sortie :

```
-----+-----
+-----+-----+-----+-----+
+-----+-----+-----+-----+
|Rule                                     |Outcome|FailureReason
|                                     |EvaluatedMetrics|
+-----+-----+-----+-----+
+-----+-----+-----+-----+
+-----+-----+-----+-----+
|ColumnExists "Provider Id"           |Passed |null
|                                     |{}|
|IsComplete "Provider Id"             |Passed |null
|                                     |{Column.Provider Id.Completeness -> 1.0}|
```

```
|ColumnValues " Total Discharges " > 15|Failed |Value: 11.0 does not meet the
  constraint requirement!|{Column. Total Discharges .Minimum -> 11.0}|
+-----+-----+
+-----+
+-----+
```

9. Filtrez les lignes ayant réussi et examinez les lignes ayant échoué dans les résultats au niveau des lignes de la qualité des données.

```
rowLevelOutcomes = SelectFromCollection.apply(
  dfc=EvaluateDataQualityMultiframe,
  key="rowLevelOutcomes",
  transformation_ctx="rowLevelOutcomes",
)

rowLevelOutcomes_df = rowLevelOutcomes.toDF() # Convert Glue DynamicFrame to
  SparkSQL DataFrame
rowLevelOutcomes_df_passed =
  rowLevelOutcomes_df.filter(rowLevelOutcomes_df.DataQualityEvaluationResult ==
    "Passed") # Filter only the Passed records.
rowLevelOutcomes_df.filter(rowLevelOutcomes_df.DataQualityEvaluationResult ==
  "Failed").show(5, truncate=False) # Review the Failed records
```

Sortie :

```
+-----+-----+
+-----+-----+-----+
+-----+-----+-----+
+-----+-----+-----+
+-----+-----+
+-----+-----+
+-----+
|DRG Definition                |Provider Id|Provider Name
      |Provider Street Address  |Provider City|Provider State|Provider Zip
Code|Hospital Referral Region Description| Total Discharges | Average Covered
Charges | Average Total Payments |Average Medicare Payments|DataQualityRulesPass
      |DataQualityRulesFail      |DataQualityRulesSkip      |
DataQualityEvaluationResult|
+-----+-----+
+-----+-----+-----+
+-----+-----+-----+
```

```

+-----+-----+-----+
+-----+-----+
+-----+-----+
+-----+
|039 - EXTRACRANIAL PROCEDURES W/O CC/MCC|10005      |MARSHALL MEDICAL CENTER SOUTH
      |2505 U S HIGHWAY 431 NORTH|BOAZ              |AL              |35957
      |AL - Birmingham              |14              |$15131.85
      |$5787.57                    |$4976.71        |[[IsComplete "Provider Id"]|
[ColumnValues " Total Discharges " > 15]]|ColumnExists "Provider Id"]|Failed
      |
|039 - EXTRACRANIAL PROCEDURES W/O CC/MCC|10046      |RIVERVIEW REGIONAL MEDICAL
CENTER  |600 SOUTH THIRD STREET  |GADSDEN        |AL              |35901
      |AL - Birmingham              |14              |$67327.92
      |$5461.57                    |$4493.57        |[[IsComplete "Provider Id"]|
[ColumnValues " Total Discharges " > 15]]|ColumnExists "Provider Id"]|Failed
      |
|039 - EXTRACRANIAL PROCEDURES W/O CC/MCC|10083      |SOUTH BALDWIN REGIONAL
MEDICAL CENTER|1613 NORTH MCKENZIE STREET|FOLEY          |AL              |36535
      |AL - Mobile                  |15              |$25411.33
      |$5282.93                    |$4383.73        |[[IsComplete "Provider
Id"]]|ColumnValues " Total Discharges " > 15]]|ColumnExists "Provider Id"]|Failed
      |
|039 - EXTRACRANIAL PROCEDURES W/O CC/MCC|30002      |BANNER GOOD SAMARITAN MEDICAL
CENTER |1111 EAST MCDOWELL ROAD  |PHOENIX        |AZ              |85006
      |AZ - Phoenix                  |11              |$34803.81
      |$7768.90                    |$6951.45        |[[IsComplete "Provider Id"]|
[ColumnValues " Total Discharges " > 15]]|ColumnExists "Provider Id"]|Failed
      |
|039 - EXTRACRANIAL PROCEDURES W/O CC/MCC|30010      |CARONDELET ST  MARYS HOSPITAL
      |1601 WEST ST MARY'S ROAD  |TUCSON         |AZ              |85745
      |AZ - Tucson                    |12              |$35968.50
      |$6506.50                    |$5379.83        |[[IsComplete "Provider Id"]|
[ColumnValues " Total Discharges " > 15]]|ColumnExists "Provider Id"]|Failed
      |
+-----+-----+-----+
+-----+-----+-----+
+-----+-----+-----+
+-----+-----+-----+
+-----+-----+-----+
+-----+-----+-----+
+-----+
only showing top 5 rows

```

Notez que AWS Glue Data Quality a ajouté quatre nouvelles colonnes (`DataQualityRulesPass`, `DataQualityRulesFail`, `DataQualityRulesSkip`, et `DataQualityEvaluationResult`). Ces colonnes indiquent les enregistrements qui ont réussi, les enregistrements qui ont échoué, les règles ignorées pour l'évaluation au niveau des lignes et les résultats globaux au niveau des lignes.

10. Écrivez la sortie dans un compartiment Amazon S3 pour analyser les données et visualiser les résultats.

```
#Write the Passed records to the destination.

glueContext.write_dynamic_frame.from_options(
    frame = rowLevelOutcomes_df_passed,
    connection_type = "s3",
    connection_options = {"path": "s3://glue-sample-target/output-dir/
medicare_parquet"},
    format = "parquet")
```

Référence DQDL (Data Quality Definition Language)

Le langage DQDL (Data Quality Definition Language) est un langage spécifique au domaine que vous utilisez pour définir des règles pour AWS Glue Data Quality.

Ce guide présente les concepts clés de DQDL pour vous aider à vous familiariser avec ce langage. Il fournit également une référence pour les types de règles DQDL, avec syntaxe et exemples. Avant d'utiliser ce guide, nous vous recommandons de vous familiariser avec AWS Glue Data Quality. Pour de plus amples informations, veuillez consulter [AWS Glue Qualité des données](#).

Note

DynamicRules ne sont pris en charge que dans AWS Glue ETL.

Table des matières

- [Syntaxe DQDL](#)
 - [Structure des règles](#)
 - [Règles composites](#)

- [Comment fonctionnent les règles composites](#)
- [Expressions](#)
 - [Mots-clés pour NULL, EMPTY et WHITESPACES_ONLY](#)
 - [Filtrer avec la clause Where](#)
- [Règles dynamiques](#)
- [Analyseurs](#)
- [Commentaires](#)
- [Référence du type de règle DQDL](#)
 - [AggregateMatch](#)
 - [ColumnCorrelation](#)
 - [ColumnCount](#)
 - [ColumnDataType](#)
 - [ColumnExists](#)
 - [ColumnLength](#)
 - [ColumnNamesMatchPattern](#)
 - [ColumnValues](#)
 - [Intégralité](#)
 - [CustomSQL](#)
 - [DataFreshness](#)
 - [DatasetMatch](#)
 - [DistinctValuesCount](#)
 - [Entropie](#)
 - [IsComplete](#)
 - [IsPrimaryKey](#)
 - [IsUnique](#)
 - [Mean](#)
 - [ReferentialIntegrity](#)
 - [RowCount](#)
 - [RowCountMatch](#)
 - [StandardDeviation](#)

- [Somme](#)
- [SchemaMatch](#)
- [Unicité](#)
- [UniqueValueRatio](#)
- [DetectAnomalies](#)
- [FileFreshness](#)
- [FileMatch](#)
- [FileUniqueness](#)
- [FileSize](#)

Syntaxe DQDL

Un document DQDL est sensible à la casse et contient un jeu de règles, qui regroupe les règles individuelles de qualité des données. Pour construire un jeu de règles, vous devez créer une liste nommée `Rules` (en majuscules), délimitée par une paire de crochets. La liste doit contenir une ou plusieurs règles DQDL séparées par des virgules, comme dans l'exemple suivant.

```
Rules = [  
    IsComplete "order-id",  
    IsUnique "order-id"  
]
```

Structure des règles

La structure d'une règle DQDL dépend du type de la règle. Toutefois, les règles DQDL respectent généralement le format suivant.

```
<RuleType> <Parameter> <Parameter> <Expression>
```

`RuleType` est le nom sensible à la casse du type de règle que vous souhaitez configurer. Par exemple, `IsComplete`, `IsUnique` ou `CustomSql`. Les paramètres varient en fonction du type de règle. Pour obtenir une référence complète des types de règles DQDL et de leurs paramètres, consultez [Référence du type de règle DQDL](#).

Règles composites

DQDL prend en charge les opérateurs logiques suivants que vous pouvez utiliser pour combiner des règles. Ces règles sont appelées règles composites.

and

L'opérateur logique and génère true si et seulement si les règles qu'il connecte sont true. Sinon, la règle combinée génère false. Chaque règle que vous connectez à l'opérateur and doit être entourée de parenthèses.

L'exemple suivant utilise l'opérateur and pour combiner deux règles DQDL.

```
(IsComplete "id") and (IsUnique "id")
```

or

L'opérateur logique or génère true si et seulement si une ou plusieurs des règles qu'il connecte sont true. Chaque règle que vous connectez à l'opérateur or doit être entourée de parenthèses.

L'exemple suivant utilise l'opérateur or pour combiner deux règles DQDL.

```
(RowCount "id" > 100) or (IsPrimaryKey "id")
```

Le même opérateur peut être utilisé pour connecter plusieurs règles. La combinaison de règles suivante est donc autorisée.

```
(Mean "Star_Rating" > 3) and (Mean "Order_Total" > 500) and (IsComplete "Order_Id")
```

Vous pouvez combiner les opérateurs logiques en une seule expression. Par exemple :

```
(Mean "Star_Rating" > 3) and ((Mean "Order_Total" > 500) or (IsComplete "Order_Id"))
```

Vous pouvez également créer des règles imbriquées plus complexes.

```
(RowCount > 0) or ((IsComplete "colA") and (IsUnique "colA"))
```

Comment fonctionnent les règles composites

Par défaut, les règles composites sont évaluées en tant que règles individuelles pour l'ensemble de données ou de la table, puis les résultats sont combinés. En d'autres termes, il évalue d'abord l'ensemble de la colonne, puis applique l'opérateur. Ce comportement par défaut est expliqué ci-dessous à l'aide d'un exemple :

```
# Dataset

+-----+-----+
|myCol1|myCol2|
+-----+-----+
|      2|      1|
|      0|      3|
+-----+-----+

# Overall outcome

+-----+-----+
|Rule                                     |Outcome|
+-----+-----+
|(ColumnValues "myCol1" > 1) OR (ColumnValues "myCol2" > 2)|Failed |
+-----+-----+
```

Dans l'exemple ci-dessus, AWS Glue Data Quality évalue d'abord (ColumnValues "myCol1" > 1) ce qui entraînera un échec. Ensuite, il évaluera (ColumnValues "myCol2" > 2) ce qui échouera également. La combinaison des deux résultats sera considérée comme un échec.

Toutefois, si vous préférez un comportement de type SQL, dans lequel vous devez évaluer la ligne entière, vous devez définir explicitement le `ruleEvaluation.scope` paramètre comme indiqué `additionalOptions` dans l'extrait de code ci-dessous.

```
object GlueApp {
  val datasource = glueContext.getCatalogSource(
    database="<db>",
    tableName="<table>",
    transformationContext="datasource"
  ).getDynamicFrame()

  val ruleset = ""
```



```

Rules = [
    (ColumnValues "age" >= 26) OR (ColumnLength "name" >= 4)
]
"""

val dq_results = EvaluateDataQuality.processRows(
    frame=datasource,
    ruleset=ruleset,
    additionalOptions=JsonOptions("""
        {
            "compositeRuleEvaluation.method":"ROW"
        }
    """)
)
}

```

Dans AWS Glue Data Catalog, vous pouvez facilement configurer cette option dans l'interface utilisateur, comme indiqué ci-dessous.

▼ Composite rule settings - *new*

Rule evaluation configuration [Info](#)

Configure how composite rules should work. [Learn more](#) 

☐ Row

The composite rules will behave as single rule evaluating entire row.

☒ Column

The composite rules will evaluate individual rules across the entire dataset and combine the results.

Une fois définies, les règles composites se comporteront comme une règle unique évaluant la ligne entière. L'exemple suivant illustre ce comportement.

```
# Row Level outcome
```

```

+-----+-----+-----+-----+
+-----+
|myCol1|myCol2|DataQualityRulesPass                                     |
DataQualityEvaluationResult|
+-----+-----+-----+-----+
+-----+
|2      |1      |[(ColumnValues "myCol1" > 1) OR (ColumnValues "myCol2" > 2)]|Passed
|      |      |
|0      |3      |[(ColumnValues "myCol1" > 1) OR (ColumnValues "myCol2" > 2)]|Passed
|      |      |
+-----+-----+-----+-----+
+-----+

```

Certaines règles ne peuvent pas être prises en charge dans cette fonctionnalité car leur résultat global repose sur des seuils ou des ratios. Ils sont listés ci-dessous.

Règles basées sur les ratios :

- Intégralité
- DatasetMatch
- ReferentialIntegrity
- Unicité

Règles dépendantes des seuils :

Lorsque les règles suivantes sont incluses dans un seuil, elles ne sont pas prises en charge. Cependant, les règles qui n'impliquent pas `with threshold` restent prises en charge.

- ColumnDataType
- ColumnValues
- CustomSQL

Expressions

Si un type de règle ne produit pas de réponse booléenne, vous devez fournir une expression en tant que paramètre afin de créer une réponse booléenne. Par exemple, la règle suivante vérifie la moyenne de toutes les valeurs d'une colonne par rapport à une expression afin de renvoyer un résultat vrai ou faux.

```
Mean "colA" between 80 and 100
```

Certains types de règles tels que `IsUnique` et `IsComplete` renvoient déjà une réponse booléenne.

Le tableau suivant répertorie les expressions pouvant être utilisées dans les règles DQDL.

Expressions DQDL prises en charge

Expression	Description	Exemple
<code>=x</code>	Correspond à <code>true</code> si la réponse du type de règle est égale à <code>x</code> .	<pre>Completeness "colA" = "1.0", ColumnValues "colA" = "2022-06-30"</pre>
<code>!=x</code>	<code>x</code> devient vrai si la réponse du type de règle n'est pas égale à <code>x</code> .	<pre>ColumnValues "colA" != "a", ColumnValues "colA" != "2022-06-30"</pre>
<code>> x</code>	Correspond à <code>true</code> si la réponse du type de règle est supérieure à <code>x</code> .	<pre>ColumnValues "colA" > 10</pre>
<code>< x</code>	Correspond à <code>true</code> si la réponse du type de règle est inférieure à <code>x</code> .	<pre>ColumnValues "colA" < 1000, ColumnValues "colA" < "2022-06-30"</pre>
<code>>= x</code>	Permet de déterminer <code>true</code> si la réponse du type de règle est supérieure ou égale à <code>x</code> .	<pre>ColumnValues "colA" >= 10</pre>
<code><= x</code>	Permet de déterminer <code>true</code> si la réponse du type de règle est inférieure ou égale à <code>x</code> .	<pre>ColumnValues "colA" <= 1000</pre>
entre <code>x</code> et <code>y</code>	Se traduit par <code>true</code> si la réponse du type de règle se situe dans une	<pre>Mean "colA" between 8 and 100,</pre>

Expression	Description	Exemple
	plage spécifiée (exclusif). Utilisez ce type d'expression uniquement pour les types numériques et date.	ColumnValues "colA" between "2022-05-31" and "2022-06-30"
pas entre <i>x</i> et <i>y</i>	Prend la valeur true si la réponse du type de règle ne se situe pas dans une plage spécifiée (incluse). Vous ne devez utiliser ce type d'expression que pour les types numériques et les dates.	ColumnValues "colA" not between "2022-05-31" and "2022-06-30"
dans [<i>a</i> , <i>b</i> , <i>c</i> , ...]	Se traduit par true si la réponse du type de règle se trouve dans le jeu spécifié.	ColumnValues "colA" in [1, 2, 3], ColumnValues "colA" in ["a", "b", "c"]
pas dans [<i>a</i> , <i>b</i> , <i>c</i> , ...]	Résout true si la réponse du type de règle ne se trouve pas dans l'ensemble spécifié.	ColumnValues "colA" not in [1, 2, 3], ColumnValues "colA" not in ["a", "b", "c"]
allumettes <i>/ab+c/i</i>	Se traduit par true si la réponse du type de règle correspond à une expression régulière.	ColumnValues "colA" matches "[a-zA-Z]*"
ne correspond pas <i>/ab+c/i</i>	Résout true si la réponse du type de règle ne correspond pas à une expression régulière.	ColumnValues "colA" not matches "[a-zA-Z]*"

Expression	Description	Exemple
<code>now()</code>	Fonctionne uniquement avec le type de règle <code>ColumnValues</code> pour créer une expression de date.	<code>ColumnValues "load_date" > (now() - 3 days)</code>
<code>matches/in [...] /not matches/notdans [...] with threshold</code>	Spécifie le pourcentage de valeurs qui correspondent aux conditions de la règle. Fonctionne uniquement avec <code>ColumnValues</code> les types de <code>CustomSQL</code> <code>règlesColumnDataType</code> , et.	<code>ColumnValues "colA" in ["A", "B"] with threshold > 0.8,</code> <code>ColumnValues "colA" matches "[a-zA-Z]*" with threshold between 0.2 and 0.9</code> <code>ColumnDataType "colA" = "Timestamp" with threshold > 0.9</code>

Mots-clés pour NULL, EMPTY et WHITESPACES_ONLY

Si vous souhaitez vérifier si une colonne de chaîne contient une valeur nulle, vide ou une chaîne contenant uniquement des espaces, vous pouvez utiliser les mots clés suivants :

- **NULL/null** — Ce mot clé prend la valeur `true` pour une `null` valeur d'une colonne de chaîne.

`ColumnValues "colA" != NULL with threshold > 0.5` renverrait vrai si plus de 50 % de vos données ne contiennent pas de valeurs nulles.

`(ColumnValues "colA" = NULL) or (ColumnLength "colA" > 5)` renverrait vrai pour toutes les lignes qui ont une valeur nulle ou dont la longueur est supérieure à 5. Notez que cela nécessitera l'utilisation de l'option « `compositeRuleEvaluation.method` » = « `ROW` ».

- **EMPTY/empty** — Ce mot clé prend la valeur `true` pour une valeur de chaîne vide (« ») dans une colonne de chaînes. Certains formats de données transforment les valeurs nulles d'une colonne de chaînes en chaînes vides. Ce mot clé permet de filtrer les chaînes vides dans vos données.

`(ColumnValues "colA" = EMPTY) or (ColumnValues "colA" in ["a", "b"])` renverrait vrai si une ligne est vide, « a » ou « b ». Notez que cela nécessite l'utilisation de l'option « `compositeRuleEvaluation.method` » = « `ROW` ».

- `WHITESPACES_ONLY/whitespaces_only` — Ce mot clé prend la valeur `true` pour une chaîne contenant uniquement des espaces blancs (« ») dans une colonne de chaîne.

`ColumnValues "colA" not in ["a", "b", WHITESPACES_ONLY]` renverrait vrai si une ligne n'est ni « a », ni « b », ni simplement des espaces.

Règles prises en charge :

- [ColumnValues](#)

Pour une expression numérique ou basée sur une date, si vous souhaitez vérifier si une colonne contient une valeur nulle, vous pouvez utiliser les mots clés suivants.

- `NULL/null` — Ce mot clé prend la valeur `true` pour une valeur nulle dans une colonne de chaîne.

`ColumnValues "colA" in [NULL, "2023-01-01"]` renverrait vrai si une date de votre colonne est nulle 2023-01-01 ou nulle.

`(ColumnValues "colA" = NULL) or (ColumnValues "colA" between 1 and 9)` renverrait vrai pour toutes les lignes qui ont une valeur nulle ou dont les valeurs sont comprises entre 1 et 9. Notez que cela nécessitera l'utilisation de l'option « `compositeRuleEvaluation .method` » = « `ROW` ».

Règles prises en charge :

- [ColumnValues](#)

Filtrer avec la clause `Where`

Note

La clause `Where` n'est prise en charge que dans AWS Glue 4.0.

Vous pouvez filtrer vos données lorsque vous créez des règles. Cela est utile lorsque vous souhaitez appliquer des règles conditionnelles.

```
<DQDL Rule> where "<valid SparkSQL where clause> "
```

Le filtre doit être spécifié avec le `where` mot clé, suivi d'une instruction SparkSQL valide entre guillemets. (`"`)

Si vous souhaitez ajouter la clause `Where` à une règle avec un seuil, la clause `Where` doit être spécifiée avant la condition de seuil.

```
<DQDL Rule> where "valid SparkSQL statement" with threshold <threshold condition>
```

Avec cette syntaxe, vous pouvez écrire des règles comme les suivantes.

```
Completeness "colA" > 0.5 where "colB = 10"
ColumnValues "colB" in ["A", "B"] where "colC is not null" with threshold > 0.9
ColumnLength "colC" > 10 where "colD != Concat(colE, colF)"
```

Nous allons vérifier que l'instruction SparkSQL fournie est valide. Si elle n'est pas valide, l'évaluation des règles échouera et nous lancerons `IllegalArgumentException` l'annonce au format suivant :

```
Rule <DQDL Rule> where "<invalid SparkSQL>" has provided an invalid where clause :
<SparkSQL Error>
```

Comportement de la clause `Where` lorsque l'identification des enregistrements d'erreur au niveau des lignes est activée

Avec AWS Glue Data Quality, vous pouvez identifier les enregistrements spécifiques qui ont échoué. Lorsque vous appliquez une clause `WHERE` à des règles qui prennent en charge les résultats au niveau des lignes, nous étiquetons les lignes filtrées par la clause `WHERE` comme `suitPassed`.

Si vous préférez étiqueter séparément les lignes filtrées comme `suitSKIPPED`, vous pouvez définir les paramètres suivants `additionalOptions` pour la tâche ETL.

```
object GlueApp {
  val datasource = glueContext.getCatalogSource(
    database="<db>",
    tableName="<table>",
    transformationContext="datasource"
  ).getDynamicFrame()

  val ruleset = ""
  Rules = [
```

```

        IsComplete "att2" where "att1 = 'a'"
    ]
    """

    val dq_results = EvaluateDataQuality.processRows(
        frame=datasource,
        ruleset=ruleset,
        additionalOptions=JsonOptions("""
            {
                "rowLevelConfiguration.filteredRowLabel":"SKIPPED"
            }
        """)
    )
}

```

À titre d'exemple, reportez-vous à la règle et à la trame de données suivantes :

```
IsComplete att2 where "att1 = 'a'"
```

id	att1	att2	Résultats au niveau des lignes (par défaut)	Résultats au niveau des lignes (option ignorée)	Commentaires
1	a	f	PASSÉ	PASSÉ	
2	b	d	PASSÉ	SKIPPED	La ligne est filtrée, car elle ne l'att1est pas "a"
3	a	null	ÉCHEC	ÉCHEC	
4	a	f	PASSÉ	PASSÉ	
5	b	null	PASSÉ	SKIPPED	La ligne est filtrée, car elle ne

id	att1	att2	Résultats au niveau des lignes (par défaut)	Résultats au niveau des lignes (option ignorée)	Commentaires
					l'att1est pas "a"
6	a	f	PASSÉ	PASSÉ	

Règles dynamiques

Note

Les règles dynamiques ne sont prises en charge que dans AWS Glue ETL et ne le sont pas dans AWS Glue Data Catalog.

Vous pouvez désormais créer des règles dynamiques pour comparer les métriques actuelles produites par vos règles avec leurs valeurs historiques. Ces comparaisons historiques sont rendues possibles en utilisant l'opérateur `last()` dans les expressions. Par exemple, la règle `RowCount > last()` fonctionne lorsque le nombre de lignes de l'exécution en cours est supérieur au nombre de lignes précédent le plus récent pour le même jeu de données. `last()` prend un argument de nombre naturel facultatif décrivant le nombre de métriques précédentes à prendre en compte ; `last(k)` où $k \geq 1$ renverra aux dernières métriques k .

- Si aucun point de données n'est disponible, `last(k)` renverra la valeur par défaut 0,0.
- Si moins de k métriques sont disponibles, `last(k)` renverra toutes les métriques précédentes.

Pour former des expressions valides, utilisez `last(k)`, où $k > 1$ nécessite une fonction d'agrégation pour réduire plusieurs résultats historiques en un seul nombre. Par exemple, `RowCount > avg(last(5))` vérifiera si le nombre de lignes du jeu de données actuel est strictement supérieur à la moyenne des cinq dernières lignes du même jeu de données. `RowCount > last(5)` générera une erreur, car le nombre de lignes du jeu de données actuel ne peut pas être comparé de manière significative à une liste.

Fonctions d'agrégation prises en charge :

- avg
- median
- max
- min
- sum
- std (écart-type)
- abs (valeur absolue)
- `index(last(k), i)` permet de sélectionner la *i*e valeur la plus récente parmi les dernières *k*. *i* est indexé à partir de zéro, donc `index(last(3), 0)` renverra le point de données le plus récent et `index(last(3), 3)` générera une erreur, car il n'y a que trois points de données et nous essayons d'indexer le 4e le plus récent.

Exemples d'expressions

ColumnCorrelation

- `ColumnCorrelation "colA" "colB" < avg(last(10))`


DistinctValuesCount

- `DistinctValuesCount "colA" between min(last(10))-1 and max(last(10))+1`

La plupart des types de règles comportant des conditions ou des seuils numériques prennent en charge les règles dynamiques. Consultez le tableau fourni, [Analyseurs et règles](#) pour vérifier si les règles dynamiques sont disponibles pour le type de règle que vous utilisez.

Exclure les statistiques des règles dynamiques

Vous devrez parfois exclure les statistiques de données de vos calculs de règles dynamiques. Supposons que vous ayez effectué un chargement de données historiques et que vous ne vouliez pas que cela ait un impact sur vos moyennes. Pour ce faire, ouvrez le job dans AWS Glue ETL et choisissez l'onglet Data Quality, puis sélectionnez Statistics et sélectionnez les statistiques que vous souhaitez exclure. Vous pourrez voir un graphique de tendance ainsi qu'un tableau de statistiques. Sélectionnez les valeurs que vous souhaitez exclure, puis choisissez Exclure les statistiques. Désormais, les statistiques exclues ne seront plus incluses dans les calculs de règles dynamiques.



Analyseurs

Note

Les analyseurs ne sont pas pris en charge dans AWS Glue Data Catalog.

Les règles DQDL utilisent des fonctions appelées analyseurs pour rassembler des informations sur vos données. Ces informations sont utilisées par l'expression booléenne d'une règle afin de décider si cette dernière doit être considérée comme réussie ou échouée. Par exemple, la RowCount règle `RowCount > 5` utilisera un analyseur de nombre de lignes pour découvrir le nombre de lignes de votre ensemble de données et comparer ce nombre à l'expression `> 5` pour vérifier s'il existe plus de cinq lignes dans le jeu de données actuel.

Il est parfois préférable, plutôt que de créer des règles, de créer des analyseurs et de les configurer pour qu'ils génèrent des statistiques utiles à la détection d'anomalies. Dans de tels cas, vous pouvez créer des analyseurs. Les analyseurs se distinguent des règles de la manière suivante.

Caractéristiques	Analyseurs	Règles
Partie du jeu de règles	Oui	Oui

Caractéristiques	Analyseurs	Règles
Génère des statistiques	Oui	Oui
Génère des observations	Oui	Oui
Peut évaluer et affirmer une condition	Non	Oui
Vous pouvez configurer des actions telles que l'arrêt des tâches en cas d'échec ou la poursuite du traitement des tâches	Non	Oui

Les analyseurs peuvent exister indépendamment sans règles, vous offrant ainsi la possibilité de les configurer rapidement et de créer progressivement des règles de qualité des données.

Certains types de règles peuvent être saisis dans le bloc **Analyzers** de votre jeu de règles afin d'exécuter les règles nécessaires aux analyseurs et rassembler des informations sans avoir à valider une quelconque condition. Certains analyseurs ne sont pas associés à des règles et ne peuvent être saisis que dans le bloc **Analyzers**. Le tableau ci-dessous précise pour chaque élément s'il est pris en charge en tant que règle ou en tant qu'analyseur autonome, avec des informations supplémentaires pour chaque type de règle.

Exemple d'ensemble de règles avec analyseur

Le jeu de règles suivant utilise :

- une règle dynamique permettant de vérifier si la croissance d'un jeu de données est supérieure à sa moyenne mobile au cours des trois dernières exécutions de tâches
- un analyseur `DistinctValuesCount` permettant d'enregistrer le nombre de valeurs distinctes dans la colonne `Name` du jeu de données
- un analyseur `ColumnLength` permettant de suivre la taille `Name` minimale et maximale au fil du temps

Les résultats des métriques de l'analyseur peuvent être consultés dans l'onglet **Qualité des données** de votre exécution de tâche.

```
Rules = [
    RowCount > avg(last(3))
]
Analyzers = [
    DistinctValuesCount "Name",
    ColumnLength "Name"
]
```

AWS Glue Data Quality prend en charge les analyseurs suivants.

Nom de l'analyseur	Fonctionnalité
RowCount	Calcule le nombre de lignes pour un ensemble de données
Completeness	Calcule le pourcentage de complétude d'une colonne
Uniqueness	Calcule le pourcentage d'unicité d'une colonne
Mean	Calcule la moyenne d'une colonne numérique
Sum	Calcule la somme d'une colonne numérique
StandardDeviation	Calcule l'écart type d'une colonne numérique
Entropy	Calcule l'entropie d'une colonne numérique
DistinctValuesCount	Calcule le nombre de valeurs distinctes dans une colonne
UniqueValueRatio	Calcule le ratio de valeurs uniques dans une colonne
ColumnCount	Calcule le nombre de colonnes d'un ensemble de données
ColumnLength	Calcule la longueur d'une colonne

Nom de l'analyseur	Fonctionnalité
ColumnValues	Calcule le minimum et le maximum pour les colonnes numériques. Calcule le minimum ColumnLength et le maximum ColumnLength pour les colonnes non numériques
ColumnCorrelation	Calcule les corrélations de colonnes pour des colonnes données
CustomSql	Calcule les statistiques renvoyées par le CustomSQL
AllStatistics	Calcule les statistiques suivantes : • RowCount, ColumnCount • Chaque colonne : Exhaustivité, unicité • Numérique : min, max, entropie, moyenne, développement standard, somme • Chaîne : MinLength, MaxLength

Commentaires

Vous pouvez utiliser le caractère « # » pour ajouter un commentaire à votre document DQDL. Tout ce qui se trouve après le caractère « # » et jusqu'à la fin de la ligne est ignoré par DQDL.

```
Rules = [  
    # More items should generally mean a higher price, so correlation should be  
    positive  
    ColumnCorrelation "price" "num_items" > 0  
]
```

Référence du type de règle DQDL

Cette section fournit une référence pour chaque type de règle pris en charge par AWS Glue Data Quality.

 Note

- Le langage DQDL ne prend actuellement pas en charge les données de colonnes imbriquées ou de type liste.
- Les valeurs entre crochets dans le tableau ci-dessous seront remplacées par les informations fournies dans les arguments des règles.
- Les règles nécessitent généralement un argument supplémentaire pour l'expression.

Rule type	Description	Argument	Métrique rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoie des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
Aggregation Match	Vérifie si deux jeux de données correspondent en comparant des métriques récapitulatives telles que le montant total des	Une ou plusieurs agrégations	Lorsque les noms de la première et de la deuxième colonne d'agrégation correspondent : Column.[Column].aggregate	Oui	Non	Non	Non	Non	Non

Rule type	Description	Argument	Métrique rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoi des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
	ventes. Utile pour permettre aux institutions financières de vérifier si toutes les données sont ingérées à partir de systèmes sources.		Lorsque les noms de la première et de la deuxième colonne d'agrégation sont différents : Column. [Column1, Column2]. groupatch						

Rule type	Description	Argument	Métrique rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoie des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
AllStatistics	Analyseur autonome permettant de recueillir plusieurs métriques pour la colonne fournie dans un ensemble de données	Un nom de colonne unique	Pour les colonnes de tous types : Dataset. .RowCount Column. [Column]. complete s Column. [Column]. iques Métrique supplémentaires pour les colonnes à valeur	Non	Oui	Non	Non	Non	Non

Rule type	Description	Argument	Métriques rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoi des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
			de chaîne : ColumnLength metrics Métriques supplémentaires pour les colonnes à valeur numérique ColumnValues metrics						
ColumnCorrelation	Vérifie si deux colonnes sont bien corrélées.	Exactement deux noms de colonne	MultipleColumnCorrelation. [Column1, Column2].ColumnCorrelation	Oui	Oui	Non	Oui	Non	Oui

Ruletype	Description	Argument	Métriques rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoi des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
ColumnCount	Vérifie si des colonnes sont supprimées.	Aucun	Dataset.ColumnCount	Oui	Oui	Non	Oui	Oui	Non
ColumnDataType	Vérifie si une colonne est conforme à un type de données	Exactement un nom de colonne	Column.ColumnName, ColumnDataType.Confiance	Oui	Non	Non	Oui, dans l'expression de seuil au niveau de la ligne	Non	Oui

Rule type	Description	Argument	Métrique rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoi des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
Column Exists	Vérifie si des colonnes existent dans un jeu de données. Cela permet aux clients de créer des plateformes de données en libre-service pour s'assurer que certaines colonnes sont	Exactement un nom de colonne	N/A	Oui	Non	Non	Non	Non	Non

Ruletype	Descripti on	Argumer	Métrique rapportée s	Prise en charge en tant que règle ?	Prise en charge en tant qu'analy seur ?	Renvoie des résultats au niveau des lignes ?	Prise en charge des règles dynamique s ?	Génère des observat ions	Supporte la syntaxe de la clause Where ?
	disponibl es.								

Rule type	Description	Argument	Métrique rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoie des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
ColumnLength	Vérifie si la longueur des données est cohérent .	Exactement un nom de colonne	ColumnLength ColumnLength Métrique supplémentaire lorsque le seuil au niveau de la ligne est fourni : ColumnLength [ColumnValue]	Oui	Oui	Oui, lorsque le seuil au niveau de la ligne est fourni	Non	Oui. Génère uniquement des observations en analysant les longueur minimale et maximale	Oui

Ruletype	Descripti on	Argumer	Métrique rapportée s	Prise en charge en tant que règle ?	Prise en charge en tant qu'analy seur ?	Renvoie des résultats au niveau des lignes ?	Prise en charge des règles dynamique s ?	Génère des observat ions	Supporte la syntaxe de la clause Where ?
s.Compl nce									
ColumnM esMatch ttern	Vérifie si les noms de colonnes correspo dent aux modèles définis. Utile pour les équipes de gouverna nce afin d'assurer la cohérence des noms de colonnes	Une expressio n régulière pour les noms de colonne	Dataset .Column mesPatt nMatchF io	Oui	Non	Non	Non	Non	Non

Rule type	Description	Argument	Métrique rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoie des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
ColumnValues	Vérifie si les données sont cohérentes par rapport aux valeurs définies. Cette règle prend en charge les expressions régulières.	Exactement un nom de colonne	Column.[Column].Minimum Column.[Column].Minimum Métrique supplémentaire lorsque le seuil au niveau de la ligne est fourni : Column.[Column].MinimumValues.Complexity	Oui	Oui	Oui, lorsque le seuil au niveau de la ligne est fourni	Non	Oui. Génère uniquement des observations en analysant les valeurs minimale et maximale	Oui

Ruletype	Description	Argument	Métriques rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoie des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
Intégralité	Vérifie la présence de données vides ou NULLs vides.	Exactement un nom de colonne	Column [Column], completer	Oui	Oui	Oui	Oui	Oui	Oui

Rule type	Description	Argument	Métrique rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoi des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
CustomSQL	Les clients peuvent implémenter presque tous les types de contrôles de qualité des données dans SQL.	Une instruction SQL (Facultatif) Un seuil au niveau de la ligne	Dataset .CustomSQL.Metric supplémentaire lorsque le seuil au niveau de la ligne est fourni : Dataset .CustomSQL.Compliance	Oui	Non	Oui, lorsque le seuil au niveau de la ligne est fourni	Oui	Non	Non
DataFreshness	Vérifie si les données sont récentes	Exactement un nom de colonne	Column.[Column].DataFreshness.Compliance	Oui	Non	Oui	Non	Non	Oui

Rule type	Description	Argument	Métrique rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoi des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
DatasetMatch	Compare deux jeux de données et détermine s'ils sont synchronisés.	Nom d'un jeu de données de référence Un mappage de colonnes (Facultatif) Colonnes pour vérifier les correspondances	Dataset [RefererDatasetNames].DatasetMatch	Oui	Non	Oui	Oui	Non	Non
DistinctValuesCount	Vérifie la présence de valeurs dupliquées.	Exactement un nom de colonne	Column [Column].distinctValuesCount	Oui	Oui	Oui	Oui	Oui	Oui

Rule type	Description	Argument	Métriques rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoi des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
Detect anomalies	Vérifie la présence d'anomalies dans les métriques rapportées par un autre type de règle.	Un type de règle	Métriques(s) rapportées(s) par l'argument du type de règle	Oui	Non	Non	Non	Non	Non
Entropie	Vérifie l'entropie des données	Exactement un nom de colonne	Column [Column].entropy	Oui	Oui	Non	Oui	Non	Oui

Ruletype	Description	Argument	Métriques rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoi des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
IsComplete	Vérifie si 100 % des données sont complètes.	Exactement un nom de colonne	Column[, Column], mplementer	Oui	Non	Oui	Non	Non	Oui

Ruletype	Description	Argument	Métrique rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoie des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
IsPrimary Key	Vérifie si une colonne est une clé primaire (non NULL et unique).	Exactement un nom de colonne	Pour une seule colonne : Column.[ColumnName]. Pour plusieurs colonnes : Multicolumn.[Comma Delimited Columns]. Uniques	Oui	Non	Oui	Non	Non	Oui
IsUnique	Vérifie si 100 % des données sont uniques.	Exactement un nom de colonne	Column.[ColumnName]. Uniques	Oui	Non	Oui	Non	Non	Oui

Rule type	Description	Argument	Métrique rapportée	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoi des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
Mean	Vérifie si la moyenne correspond au seuil défini.	Exactement un nom de colonne	Column [Column].	Oui	Oui	Oui	Oui	Non	Oui
Referential Integrity	Vérifie si deux jeux de données ont une intégrité référentielle.	Un ou plusieurs noms de colonne provenant du jeu de données Un ou plusieurs noms de colonnes issus du jeu de données de référence	Column [Referential Integrity]	Oui	Non	Oui	Oui	Non	Non

Rule type	Description	Argument	Métrique rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoie des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
RowCount	Vérifie si le nombre d'enregistrements correspond à un seuil.	Aucun	Dataset.RowCount	Oui	Oui	Non	Oui	Oui	Oui
RowCountMatch	Vérifie si le nombre d'enregistrements entre deux jeux de données correspond.	Alias de jeu de données de référence	Dataset [RefererDatasetAlias].RowCountMatch	Oui	Non	Non	Oui	Non	Non
StandardDeviation	Vérifie si l'écart type correspond au seuil.	Exactement un nom de colonne	Column [Column].StandardDeviation	Oui	Oui	Oui	Oui	Non	Oui

Rule type	Description	Argument	Métrique rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoie des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
SchemaMatch	Vérifie si le schéma entre deux jeux de données correspond.	Alias de jeu de données de référence	Dataset [RefererDatasetAlias].SchemaMatch	Oui	Non	Non	Oui	Non	Non
Somme	Vérifie si la somme correspond à un seuil défini.	Exactement un nom de colonne	Column [Column].nom	Oui	Oui	Non	Oui	Non	Oui
Unicité	Vérifie si l'unicité du jeu de données correspond au seuil.	Exactement un nom de colonne	Column [Column].iques	Oui	Oui	Oui	Oui	Non	Oui

Rule type	Description	Argument	Métrique rapportée	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoi des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
UniqueValueRatio	Vérifie si le ratio de valeur unique correspond au seuil.	Exactement un nom de colonne	ColumnUniqueValueRatio	Oui	Oui	Oui	Oui	Non	Oui
FileFreshness	Vérifie si les fichiers d'Amazon S3 sont récents.	Chemin du fichier ou du dossier et seuil.	DatasetFileFreshness.DatasetFileCount	Oui	Non	Non	Non	Non	Non

Ruletype	Description	Argument	Métrique rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoi des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
FileMatch	Vérifie si le contenu du fichier correspond à une somme de contrôle ou à un autre fichier. Cette règle utilise des checksums pour valider si deux fichiers sont identiques.	Chemin du fichier ou du dossier source et chemin du fichier ou du dossier cible.	Aucune statistique n'est générée.	Oui	Non	Non	Non	Non	Non

Ruletype	Description	Argument	Métriques rapportées	Prise en charge en tant que règle ?	Prise en charge en tant qu'analyseur ?	Renvoi des résultats au niveau des lignes ?	Prise en charge des règles dynamiques ?	Génère des observations	Supporte la syntaxe de la clause Where ?
FileSize	Vérifie si la taille d'un fichier ou du dossier correspond à une condition spécifiée.	Chemin et seuil du fichier ou du dossier.	Dataset .FileSize Dataset .Completeness Dataset .FileCount Dataset .MaximumFileSize Dataset .MinimumFileSize	Oui	Non	Non	Non	Non	Non
FileUniqueness	Vérifie si les fichiers sont uniques à l'aide de sommes de contrôle.	Chemin et seuil du fichier ou du dossier.	Dataset .FileUniqueness Dataset .FileCount	Oui	Non	Non	Non	Non	Non

Rubriques

- [AggregateMatch](#)
- [ColumnCorrelation](#)
- [ColumnCount](#)
- [ColumnDataType](#)
- [ColumnExists](#)
- [ColumnLength](#)
- [ColumnNamesMatchPattern](#)
- [ColumnValues](#)
- [Intégralité](#)
- [CustomSQL](#)
- [DataFreshness](#)
- [DatasetMatch](#)
- [DistinctValuesCount](#)
- [Entropie](#)
- [IsComplete](#)
- [IsPrimaryKey](#)
- [IsUnique](#)
- [Mean](#)
- [ReferentialIntegrity](#)
- [RowCount](#)
- [RowCountMatch](#)
- [StandardDeviation](#)
- [Somme](#)
- [SchemaMatch](#)
- [Unicité](#)
- [UniqueValueRatio](#)
- [DetectAnomalies](#)
- [FileFreshness](#)
- [FileMatch](#)
- [FileUniqueness](#)

- [FileSize](#)

AggregateMatch

Vérifie le ratio de deux agrégations de colonnes par rapport à une expression donnée. Ce type de règle fonctionne sur plusieurs jeux de données. Les deux agrégations de colonnes sont évaluées et un ratio est produit en divisant le résultat de la première agrégation de colonnes par le résultat de la seconde agrégation de colonnes. Le ratio est vérifié par rapport à l'expression fournie pour produire une réponse booléenne.

Syntaxe

Agrégation de colonnes

```
AggregateMatch <AGG_OPERATION> (<OPTIONAL_REFERENCE_ALIAS>.<COL_NAME>)
```

- AGG_OPERATION : l'opération à utiliser pour l'agrégation. À l'heure actuelle, sum et avg sont pris en charge.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- OPTIONAL_REFERENCE_ALIAS : ce paramètre doit être fourni si la colonne provient d'un jeu de données de référence et non du jeu de données principal. Si vous utilisez cette règle dans le catalogue de données AWS Glue, votre alias de référence doit suivre le format « »<database_name>. <table_name>. <column_name>

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- COL_NAME : le nom de la colonne à agréger.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

Exemple : moyenne

```
"avg(rating)"
```

Exemple : somme

```
"sum(amount)"
```

Exemple : moyenne de la colonne dans le jeu de données de référence

```
"avg(reference.rating)"
```

Règle

```
AggregateMatch <AGG_EXP_1> <AGG_EXP_2> <EXPRESSION>
```

- AGG_EXP_1 : la première agrégation de colonnes.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- AGG_EXP_2 : la deuxième agrégation de colonnes.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- EXPRESSION – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour de plus amples informations, veuillez consulter [Expressions](#).

Exemple : correspondance agrégée à l'aide de la somme

L'exemple de règle suivant vérifie si la somme des valeurs de la colonne `amount` est exactement égale à la somme des valeurs de la colonne `total_amount`.

```
AggregateMatch "sum(amount)" "sum(total_amount)" = 1.0
```

Exemple : correspondance agrégée à l'aide de la moyenne

L'exemple de règle suivant vérifie si la moyenne des valeurs de la colonne `ratings` est égale à au moins 90 % de la moyenne des valeurs de la colonne `ratings` dans le jeu de données `reference`. Le jeu de données de référence est fourni en tant que source de données supplémentaire dans l'expérience ETL ou le catalogue de données.

Dans AWS Glue ETL, vous pouvez utiliser :

```
AggregateMatch "avg(ratings)" "avg(reference.ratings)" >= 0.9
```

Dans le catalogue de données AWS Glue, vous pouvez utiliser :

```
AggregateMatch "avg(ratings)" "avg(database_name.tablename.ratings)" >= 0.9
```

Comportement nul

La `AggregateMatch` règle ignorera les lignes contenant des valeurs NULL dans le calcul des méthodes d'agrégation (somme/moyenne). Par exemple :

```
+---+-----+
|id |units   |
+---+-----+
|100|0       |
|101|null   |
|102|20     |
|103|null   |
|104|40     |
+---+-----+
```

La moyenne de la colonne `units` sera $(0 + 20 + 40)/3 = 20$. Les lignes 101 et 103 ne sont pas prises en compte dans ce calcul.

ColumnCorrelation

Vérifie la corrélation entre deux colonnes par rapport à une expression donnée. AWS Glue Data Quality utilise le coefficient de corrélation de Pearson pour mesurer la corrélation linéaire entre deux colonnes. Le résultat est un nombre compris entre -1 et 1 qui mesure la force et la direction de la relation.

Syntaxe

```
ColumnCorrelation <COL_1_NAME> <COL_2_NAME> <EXPRESSION>
```

- `COL_1_NAME` – Nom de la première colonne par rapport à laquelle vous souhaitez évaluer la règle de qualité des données.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- `COL_2_NAME` – Nom de la deuxième colonne par rapport à laquelle vous souhaitez évaluer la règle de qualité des données.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- **EXPRESSION** – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour plus d'informations, consultez [Expressions](#).

Exemple : corrélation de colonnes

L'exemple de règle suivant vérifie si le coefficient de corrélation entre les colonnes `height` et `weight` présente une forte corrélation positive (valeur de coefficient supérieure à 0,8).

```
ColumnCorrelation "height" "weight" > 0.8
```

```
ColumnCorrelation "weightinkgs" "Salary" > 0.8 where "weightinkgs" > 40
```

Exemples de règles dynamiques

- `ColumnCorrelation "colA" "colB" between min(last(10)) and max(last(10))`
- `ColumnCorrelation "colA" "colB" < avg(last(5)) + std(last(5))`

Comportement nul

La `ColumnCorrelation` règle ignorera les lignes contenant NULL des valeurs dans le calcul de la corrélation. Par exemple :

```
+---+-----+
|id |units   |
+---+-----+
|100|0       |
|101|null   |
|102|20     |
|103|null   |
|104|40     |
+---+-----+
```

Les lignes 101 et 103 seront ignorées, et `ColumnCorrelation` ce sera 1.0.

ColumnCount

Vérifie le nombre de colonnes du jeu de données principal par rapport à une expression donnée. Dans l'expression, vous pouvez spécifier le nombre de colonnes ou une plage de colonnes à l'aide d'opérateurs tels que `>` et `<`.

Syntaxe

```
ColumnCount <EXPRESSION>
```

- **EXPRESSION** – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour de plus amples informations, veuillez consulter [Expressions](#).

Exemple : vérification numérique du nombre de colonnes

L'exemple de règle suivant vérifie si le nombre de colonnes est compris dans une plage donnée.

```
ColumnCount between 10 and 20
```

Exemples de règles dynamiques

- `ColumnCount >= avg(last(10))`
- `ColumnCount between min(last(10))-1 and max(last(10))+1`

ColumnDataType

Vérifie si les valeurs d'une colonne donnée peuvent être converties dans Apache Spark dans le type fourni. Accepte une expression `with threshold` pour vérifier la présence d'un sous-ensemble des valeurs de la colonne.

Syntaxe

```
ColumnDataType <COL_NAME> = <EXPECTED_TYPE>
```

- **COL_NAME** – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : type de chaîne

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- **EXPECTED_TYPE** : le type attendu des valeurs de la colonne.

Valeurs prises en charge : booléen, date, horodatage, entier, double, flottant, long

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- **EXPRESSION** : une expression facultative pour spécifier le pourcentage de valeurs qui doivent être du type attendu.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

Exemple : les entiers de type colonne en tant que chaînes

L'exemple de règle suivant vérifie si les valeurs de la colonne donnée, qui est de type chaîne, peuvent être converties en entiers.

```
ColumnDataType "colA" = "INTEGER"
```

Exemple : les entiers de type colonne en tant que chaînes de caractères vérifient un sous-ensemble de valeurs.

L'exemple de règle suivant vérifie si plus de 90 % des valeurs de la colonne donnée, qui est de type chaîne, peuvent être converties en entiers.

```
ColumnDataType "colA" = "INTEGER" with threshold > 0.9
```

ColumnExists

Vérifie si une colonne existe.

Syntaxe

```
ColumnExists <COL_NAME>
```

- **COL_NAME** – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : n'importe quel type de colonne

Exemple : une colonne existe

L'exemple de règle suivant vérifie si la colonne nommée `Middle_Name` existe.

```
ColumnExists "Middle_Name"
```

ColumnLength

Vérifie si la longueur de chaque ligne d'une colonne est conforme à une expression donnée.

Syntaxe

```
ColumnLength <COL_NAME><EXPRESSION>
```

- COL_NAME – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : chaîne

- EXPRESSION – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour plus d'informations, consultez [Expressions](#).

Exemple : longueur de ligne de colonne

L'exemple de règle suivant vérifie si la valeur de chaque ligne de la colonne nommée Postal_Code est constituée de 5 caractères.

```
ColumnLength "Postal_Code" = 5  
ColumnLength "weightinkgs" = 2 where "weightinkgs" > 10"
```

Comportement nul

La ColumnLength règle traite NULL s comme des chaînes de 0 longueur. Pour une NULL ligne :

```
ColumnLength "Postal_Code" > 4 # this will fail
```

```
ColumnLength "Postal_Code" < 6 # this will succeed
```

L'exemple de règle composée suivant fournit un moyen d'annuler explicitement des NULL valeurs :

```
(ColumnLength "Postal_Code" > 4) AND (ColumnValues "Postal_Code" != NULL)
```

ColumnNamesMatchPattern

Vérifie si les noms de toutes les colonnes du jeu de données principal correspondent à l'expression régulière donnée.

Syntaxe

```
ColumnNamesMatchPattern <PATTERN>
```

- **PATTERN** : le modèle par rapport auquel vous souhaitez évaluer la règle de qualité des données.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

Exemple : les noms de colonnes correspondent au modèle

L'exemple de règle suivant vérifie si toutes les colonnes commencent par le préfixe « aws_ »

```
ColumnNamesMatchPattern "aws_.*"  
ColumnNamesMatchPattern "aws_.*" where "weightinkgs > 10"
```

ColumnValues

Exécute une expression en fonction des valeurs d'une colonne.

Syntaxe

```
ColumnValues <COL_NAME> <EXPRESSION>
```

- **COL_NAME** – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : n'importe quel type de colonne

- **EXPRESSION** – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour plus d'informations, consultez [Expressions](#).

Exemple : valeurs autorisées

L'exemple de règle suivant vérifie si chaque valeur de la colonne spécifiée fait partie d'un ensemble de valeurs autorisées (y compris les valeurs nulles, vides et les chaînes contenant uniquement des espaces).

```
ColumnValues "Country" in [ "US", "CA", "UK", NULL, EMPTY, WHITESPACES_ONLY ]  
ColumnValues "gender" in ["F", "M"] where "weightinkgs < 10"
```

Exemple : expression régulière

L'exemple de règle suivant compare les valeurs d'une colonne à une expression régulière.

```
ColumnValues "First_Name" matches "[a-zA-Z]*"
```

Exemple : valeurs de date

L'exemple de règle suivant compare les valeurs d'une colonne de date à une expression de date.

```
ColumnValues "Load_Date" > (now() - 3 days)
```

Exemple : valeurs numériques

L'exemple de règle suivant vérifie si les valeurs des colonnes correspondent à une certaine contrainte numérique.

```
ColumnValues "Customer_ID" between 1 and 2000
```

Comportement nul

Pour toutes les ColumnValues règles (à l'exception de != et NOT IN), NULL les lignes ne seront pas respectées. Si la règle échoue en raison d'une valeur nulle, la raison de l'échec s'affichera comme suit :

```
Value: NULL does not meet the constraint requirement!
```

L'exemple de règle composée suivant fournit un moyen d'autoriser explicitement les NULL valeurs :

```
(ColumnValues "Age" > 21) OR (ColumnValues "Age" = NULL)
```

ColumnValues Les règles annulées utilisant la not in syntaxe != et seront transmises aux NULL lignes. Par exemple :

```
ColumnValues "Age" != 21
```

```
ColumnValues "Age" not in [21, 22, 23]
```

Les exemples suivants fournissent un moyen d'annuler explicitement des NULL valeurs

```
(ColumnValues "Age" != 21) AND (ColumnValues "Age" != NULL)
```

```
ColumnValues "Age" not in [21, 22, 23, NULL]
```

Intégralité

Compare le pourcentage de valeurs complètes (non nulles) d'une colonne à une expression donnée.

Syntaxe

```
Completeness <COL_NAME> <EXPRESSION>
```

- COL_NAME – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : n'importe quel type de colonne

- EXPRESSION – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour plus d'informations, consultez [Expressions](#).

Exemple : pourcentage de valeur nulle

Les exemples de règles suivants vérifient si plus de 95 % des valeurs d'une colonne sont complètes.

```
Completeness "First_Name" > 0.95  
Completeness "First_Name" > 0.95 where "weightinkgs" > 10
```

Exemples de règles dynamiques

- Completeness "colA" between min(last(5)) - 1 and max(last(5)) + 1
- Completeness "colA" <= avg(last(10))

Comportement nul

Remarque sur les formats de données CSV : les lignes vides des colonnes CSV peuvent afficher plusieurs comportements.

- Si une colonne est de String type, la ligne vide sera reconnue comme une chaîne vide et ne dérogera pas à la Completeness règle.

- Si une colonne est d'un autre type de données `Int`, la ligne vide sera reconnue `NULL` et ne respectera pas la `Completeness` règle.

CustomSQL

Ce type de règle a été étendu pour prendre en charge deux cas d'utilisation :

- Exécutez une instruction SQL personnalisée sur un jeu de données et compare la valeur renvoyée à une expression donnée.
- Exécutez une instruction SQL personnalisée dans laquelle vous spécifiez un nom de colonne dans votre instruction `SELECT`, que vous comparez à une certaine condition pour obtenir des résultats au niveau des lignes.

Syntaxe

```
CustomSql <SQL_STATEMENT> <EXPRESSION>
```

- `SQL_STATEMENT` – Instruction SQL qui renvoie une valeur numérique unique, entourée de guillemets doubles.
- `EXPRESSION` – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour de plus amples informations, veuillez consulter [Expressions](#).

Exemple : SQL personnalisé pour récupérer le résultat global d'une règle

Cet exemple de règle utilise une instruction SQL pour récupérer le nombre d'enregistrements d'un jeu de données. La règle vérifie ensuite que le nombre d'enregistrements est compris entre 10 et 20.

```
CustomSql "select count(*) from primary" between 10 and 20
```

Exemple : SQL personnalisé pour récupérer les résultats au niveau des lignes

Cet exemple de règle utilise une instruction SQL dans laquelle vous spécifiez un nom de colonne dans votre instruction `SELECT`, que vous comparez à une certaine condition pour obtenir des résultats au niveau des lignes. Une expression de condition de seuil définit le nombre d'enregistrements qui doivent échouer pour que l'ensemble de la règle échoue. Notez qu'une règle ne peut pas contenir à la fois une condition et un mot clé.


```
CustomSql "select Name from primary where Age > 18"
```

or

```
CustomSql "select Name from primary where Age > 18" with threshold > 3
```

Important

L'alias `primary` est le nom du jeu de données que vous souhaitez évaluer. Lorsque vous utilisez des tâches ETL visuelles sur la console, `primary` représente toujours le `DynamicFrame` qui est transmis à la transformation `EvaluateDataQuality.apply()`. Lorsque vous utilisez le catalogue de données AWS Glue pour exécuter des tâches de qualité des données sur une table, `primary` représente la table.

Si vous êtes dans AWS Glue Catalogue de données, vous pouvez également utiliser les noms de table réels :

```
CustomSql "select count(*) from database.table" between 10 and 20
```

Vous pouvez également joindre plusieurs tables pour comparer différents éléments de données :

```
CustomSql "select count(*) from database.table inner join database.table2 on id1 = id2"
between 10 and 20
```

Entrée AWS Glue ETL, CustomSQL peuvent identifier les enregistrements qui ont échoué aux contrôles de qualité des données. Pour que cela fonctionne, vous devez renvoyer les enregistrements qui font partie de la table principale pour laquelle vous évaluez la qualité des données. Les enregistrements renvoyés dans le cadre de la requête sont considérés comme réussis et les enregistrements non renvoyés sont considérés comme ayant échoué. Cela fonctionne en joignant le résultat de votre requête CustomSQL à l'ensemble de données d'origine. La complexité de votre requête SQL peut avoir des répercussions sur les performances.

Pour cela :

- Vous devez sélectionner au moins une colonne dans votre table principale.
 - `select count(*) from primary` est une requête valide pour la règle OVERALL CustomSQL DQ, mais pas pour le SQL personnalisé au niveau des lignes.

- Cette règle générera une erreur lors de l'évaluation : The output from CustomSQL must contain at least one column that matches the input dataset for AWS Glue Data Quality to provide row level results. The SQL query is a valid query but the columns from the SQL result are not present in the Input Dataset. Ensure that matching columns are returned from the SQL.
- Dans votre requête SQL, sélectionnez une « clé primaire » dans votre table ou sélectionnez un ensemble de colonnes qui forment une clé composite. Ne pas le faire peut entraîner des résultats incohérents en raison de la correspondance de lignes dupliquées et d'une dégradation des performances.
- Sélectionnez les clés UNIQUEMENT dans votre table principale et non dans vos tables de référence.

La règle suivante permet de s'assurer que les enregistrements dont l'âge est inférieur à 100 sont identifiés comme réussis et que les enregistrements dont l'âge est supérieur sont marqués comme échoués.

```
CustomSql "select id from primary where age < 100"
```

Cette règle CustomSQL sera validée si 50 % des enregistrements ont un âge supérieur à 10 et identifiera également les enregistrements qui ont échoué. Les enregistrements renvoyés par cette règle CustomSQL seront considérés comme réussis, tandis que ceux non renvoyés seront considérés comme ayant échoué.

```
CustomSQL "select ID, CustomerID from primary where age > 10" with threshold > 0.5
```

Remarque : la règle CustomSQL échoue si vous renvoyez des enregistrements qui ne sont pas disponibles dans le jeu de données.

DataFreshness

Vérifie l'actualisation des données d'une colonne en évaluant la différence entre l'heure actuelle et les valeurs d'une colonne de date. Pour ce type de règle, vous pouvez spécifier une expression temporelle afin de vérifier que les valeurs des colonnes sont à jour.

Syntaxe

```
DataFreshness <COL_NAME> <EXPRESSION>
```

- COL_NAME – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonne pris en charge : Date

- EXPRESSION – Expression numérique exprimée en heures ou en jours. Vous devez spécifier l'unité de temps dans votre expression.

Exemple : actualisation des données

Les exemples de règles suivants vérifient l'actualisation des données.

```
DataFreshness "Order_Date" <= 24 hours
DataFreshness "Order_Date" between 2 days and 5 days
```

Comportement nul

Les DataFreshness règles échoueront pour les lignes contenant des NULL valeurs. Si la règle échoue en raison d'une valeur nulle, la raison de l'échec s'affichera comme suit :

```
80.00 % of rows passed the threshold
```

où 20 % des lignes qui ont échoué incluent les lignes avecNULL.

L'exemple de règle composée suivant fournit un moyen d'autoriser explicitement les NULL valeurs :

```
(DataFreshness "Order_Date" <= 24 hours) OR (ColumnValues "Order_Date" = NULL)
```

Data Freshness pour les objets Amazon S3

Vous devrez parfois valider l'actualité des données en fonction de l'heure de création du fichier Amazon S3. Pour ce faire, vous pouvez utiliser le code suivant pour obtenir l'horodatage et l'ajouter à votre dataframe, puis appliquer des contrôles de fraîcheur des données.

```
df = glueContext.create_data_frame.from_catalog(database = "default", table_name =
  "mytable")
df = df.withColumn("file_ts", df["_metadata.file_modification_time"])

Rules = [
  DataFreshness "file_ts" < 24 hours
]
```

DatasetMatch

Vérifie si les données du jeu de données principal correspondent aux données d'un jeu de données de référence. Les deux jeux de données sont joints à l'aide des mappages de colonnes clés fournis. Des mappages de colonnes supplémentaires peuvent être fournis si vous souhaitez vérifier l'égalité des données uniquement dans ces colonnes. Notez que DatasetMatch pour fonctionner, vos clés de jointure doivent être uniques et ne pas être NULL (elles doivent être une clé primaire). Si vous ne remplissez pas ces conditions, le message d'erreur suivant affiche : « La clé de distribution fournie ne convient pas à des cadres de données donnés ». Dans les cas où vous ne pouvez pas avoir de clés jointes uniques, envisagez d'utiliser d'autres types de règles, par exemple AggregateMatch pour établir une correspondance sur des données récapitulatives.

Syntaxe

```
DatasetMatch <REFERENCE_DATASET_ALIAS> <JOIN_CONDITION_WITH  
MAPPING> <OPTIONAL_MATCH_COLUMN_MAPPINGS> <EXPRESSION>
```

- **REFERENCE_DATASET_ALIAS** : l'alias du jeu de données de référence avec lequel vous comparez les données du jeu de données principal.
- **KEY_COLUMN_MAPPINGS** : une liste de noms de colonnes séparés par des virgules qui forment une clé dans les jeux de données. Si les noms de colonnes ne sont pas identiques dans les deux jeux de données, vous devez les séparer par ->
- **OPTIONAL_MATCH_COLUMN_MAPPINGS** : vous pouvez fournir ce paramètre si vous souhaitez vérifier les données correspondantes uniquement dans certaines colonnes. Il utilise la même syntaxe que les mappages de colonnes clés. Si ce paramètre n'est pas fourni, la correspondance portera sur les données de toutes les autres colonnes. Les autres colonnes non-clés doivent porter le même nom dans les deux jeux de données.
- **EXPRESSION** – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour de plus amples informations, veuillez consulter [Expressions](#).

Exemple : faire correspondre des jeux de données à l'aide de la colonne ID

L'exemple de règle suivant vérifie que plus de 90 % du jeu de données principal correspond au jeu de données de référence, en utilisant la colonne « ID » pour joindre les deux jeux de données. Dans ce cas, toutes les colonnes sont comparées.

```
DatasetMatch "reference" "ID" >= 0.9
```

Exemple : faire correspondre des jeux de données en utilisant plusieurs colonnes clés

Dans l'exemple suivant, le jeu de données principal et le jeu de données de référence portent des noms différents pour les colonnes clés. ID_1 et ID_2 forment ensemble une clé composite dans le jeu de données principal. ID_ref1 et ID_ref2 forment ensemble une clé composite dans le jeu de données de référence. Dans ce scénario, vous pouvez utiliser la syntaxe spéciale pour fournir les noms des colonnes.

```
DatasetMatch "reference" "ID_1->ID_ref1,ID_ref2->ID_ref2" >= 0.9
```

Exemple : faire correspondre des jeux de données à l'aide de plusieurs colonnes clés et vérifier qu'une colonne spécifique correspond

Cet exemple s'appuie sur l'exemple précédent. Nous voulons vérifier que seule la colonne contenant les montants correspond. Cette colonne est nommée Amount1 dans le jeu de données principal et Amount2 dans le jeu de données de référence. Une correspondance exacte est désirée.

```
DatasetMatch "reference" "ID_1->ID_ref1,ID_2->ID_ref2" "Amount1->Amount2" >= 0.9
```

DistinctValuesCount

Vérifie le nombre de valeurs distinctes dans une colonne par rapport à une expression donnée.

Syntaxe

```
DistinctValuesCount <COL_NAME> <EXPRESSION>
```

- COL_NAME – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : n'importe quel type de colonne

- EXPRESSION – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour plus d'informations, consultez [Expressions](#).

Exemple : nombre de valeurs de colonne distinctes

L'exemple de règle suivant vérifie que la colonne nommée State contient plus de 3 valeurs distinctes.

```
DistinctValuesCount "State" > 3  
DistinctValuesCount "Customer_ID" < 6  where "Customer_ID < 10"
```

Exemples de règles dynamiques

- `DistinctValuesCount "colA" between avg(last(10))-1 and avg(last(10))+1`
- `DistinctValuesCount "colA" <= index(last(10),2) + std(last(5))`

Entropie

Vérifie si la valeur d'entropie d'une colonne correspond à une expression donnée. L'entropie mesure le niveau d'information contenu dans un message. Compte tenu de la distribution de probabilité des valeurs d'une colonne, l'entropie décrit le nombre de bits nécessaires pour identifier une valeur.

Syntaxe

```
Entropy <COL_NAME> <EXPRESSION>
```

- **COL_NAME** – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : n'importe quel type de colonne

- **EXPRESSION** – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour plus d'informations, consultez [Expressions](#).

Exemple : entropie de colonne

L'exemple de règle suivant vérifie que la colonne nommée Feedback possède une valeur d'entropie supérieure à un.

```
Entropy "Star_Rating" > 1  
Entropy "First_Name" > 1  where "Customer_ID < 10"
```

Exemples de règles dynamiques

- `Entropy "colA" < max(last(10))`
- `Entropy "colA" between min(last(10)) and max(last(10))`

IsComplete

Vérifie si toutes les valeurs d'une colonne sont complètes (non nulles).

Syntaxe

```
IsComplete <COL_NAME>
```

- COL_NAME – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : n'importe quel type de colonne

Exemple : valeurs nulles

L'exemple suivant vérifie si toutes les valeurs d'une colonne nommée email ne sont pas nulles.

```
IsComplete "email"  
IsComplete "Email" where "Customer_ID between 1 and 50"  
IsComplete "Customer_ID" where "Customer_ID < 16 and Customer_ID != 12"  
IsComplete "passenger_count" where "payment_type<>0"
```

Comportement nul

Remarque sur les formats de données CSV : les lignes vides des colonnes CSV peuvent afficher plusieurs comportements.

- Si une colonne est de String type, la ligne vide sera reconnue comme une chaîne vide et ne dérogera pas à la Completeness règle.
- Si une colonne est d'un autre type de données Int, la ligne vide sera reconnue NULL et ne respectera pas la Completeness règle.

IsPrimaryKey

Vérifie si une colonne contient une clé primaire. Une colonne contient une clé primaire si toutes les valeurs de la colonne sont uniques et complètes (non nulles). Vous pouvez également vérifier la présence de clés primaires comportant plusieurs colonnes.

Syntaxe

```
IsPrimaryKey <COL_NAME>
```

- COL_NAME – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : n'importe quel type de colonne

Exemple : clé primaire

L'exemple de règle suivant vérifie si la colonne nommée Customer_ID contient une clé primaire.

```
IsPrimaryKey "Customer_ID"  
IsPrimaryKey "Customer_ID" where "Customer_ID < 10"
```

Exemple : clé primaire avec plusieurs colonnes. Tous les exemples suivants sont valides.

```
IsPrimaryKey "colA" "colB"  
IsPrimaryKey "colA" "colB" "colC"  
IsPrimaryKey colA "colB" "colC"
```

IsUnique

Vérifie si toutes les valeurs d'une colonne sont uniques et renvoie une valeur booléenne.

Syntaxe

```
IsUnique <COL_NAME>
```

- COL_NAME – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : n'importe quel type de colonne

Exemples

L'exemple de règle suivant vérifie si toutes les valeurs d'une colonne nommée email sont uniques.

```
IsUnique "email"
```



```
IsUnique "Customer_ID" where "Customer_ID < 10"]
```

L'exemple de règle suivant vérifie plusieurs colonnes.

```
IsUnique "vendorid" "tpep_pickup_datetime"
```

Mean

Vérifie si la moyenne de toutes les valeurs d'une colonne correspond à une expression donnée.

Syntaxe

```
Mean <COL_NAME> <EXPRESSION>
```

- COL_NAME – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- EXPRESSION – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour plus d'informations, consultez [Expressions](#).

Exemple : valeur moyenne

L'exemple de règle suivant vérifie si la moyenne de toutes les valeurs d'une colonne dépasse un seuil.

```
Mean "Star_Rating" > 3  
Mean "Salary" < 6200 where "Customer_ID < 10"
```

Exemples de règles dynamiques

- Mean "colA" > avg(last(10)) + std(last(2))
- Mean "colA" between min(last(5)) - 1 and max(last(5)) + 1

Comportement nul

La Mean règle ignorera les lignes contenant NULL des valeurs dans le calcul de la moyenne. Par exemple :

```
+---+-----+
|id |units   |
+---+-----+
|100|0       |
|101|null    |
|102|20      |
|103|null    |
|104|40      |
+---+-----+
```

La moyenne de la colonne `units` sera $(0 + 20 + 40)/3 = 20$. Les lignes 101 et 103 ne sont pas prises en compte dans ce calcul.

ReferentialIntegrity

Vérifie dans quelle mesure les valeurs d'un ensemble de colonnes du jeu de données principal sont un sous-ensemble des valeurs d'un ensemble de colonnes d'un jeu de données de référence.

Syntaxe

```
ReferentialIntegrity <PRIMARY_COLS> <REFERENCE_DATASET_COLS> <EXPRESSION>
```

- **PRIMARY_COLS** : une liste de noms de colonnes séparés par des virgules dans le jeu de données principal.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- **REFERENCE_DATASET_COLS** : ce paramètre contient deux parties séparées par un point. La première partie est l'alias du jeu de données de référence. La deuxième partie est la liste des noms de colonnes du jeu de données de référence, séparés par des virgules et placés entre accolades.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- **EXPRESSION** – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour de plus amples informations, veuillez consulter [Expressions](#).

Exemple : vérifier l'intégrité référentielle d'une colonne de code postal

L'exemple de règle suivant vérifie que plus de 90 % des valeurs de la colonne `zipcode` du jeu de données principal sont présentes dans la colonne `zipcode` du jeu de données `reference`.

```
ReferentialIntegrity "zipcode" "reference.zipcode" >= 0.9
```

Exemple : vérifier l'intégrité référentielle des colonnes de ville et d'État

Dans l'exemple suivant, des colonnes contenant des informations sur la ville et l'État existent dans le jeu de données principal et dans le jeu de données de référence. Les noms des colonnes sont différents dans les deux jeux de données. La règle vérifie si l'ensemble de valeurs des colonnes du jeu de données principal est exactement égal à l'ensemble de valeurs des colonnes du jeu de données de référence.

```
ReferentialIntegrity "city,state" "reference.{ref_city,ref_state}" = 1.0
```

Exemples de règles dynamiques

- `ReferentialIntegrity "city,state" "reference.{ref_city,ref_state}" > avg(last(10))`
- `ReferentialIntegrity "city,state" "reference.{ref_city,ref_state}" between min(last(10)) - 1 and max(last(10)) + 1`

RowCount

Vérifie le nombre de lignes d'un jeu de données par rapport à une expression donnée. Dans l'expression, vous pouvez spécifier le nombre de lignes ou une plage de lignes à l'aide d'opérateurs tels que `>` et `<`.

Syntaxe

```
RowCount <EXPRESSION>
```

- **EXPRESSION** – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour plus d'informations, consultez [Expressions](#).

Exemple : vérification numérique du nombre de lignes

L'exemple de règle suivant vérifie si le nombre de lignes est compris dans une plage donnée.

```
RowCount between 10 and 100
```

```
RowCount between 1 and 50 where "Customer_ID < 10"
```

Exemples de règles dynamiques

```
RowCount > avg(last(10)) *0.8
```

RowCountMatch

Vérifie le rapport entre le nombre de lignes du jeu de données principal et le nombre de lignes d'un jeu de données de référence par rapport à l'expression donnée.

Syntaxe

```
RowCountMatch <REFERENCE_DATASET_ALIAS> <EXPRESSION>
```

- **REFERENCE_DATASET_ALIAS** : alias du jeu de données de référence par rapport auquel comparer le nombre de lignes.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- **EXPRESSION** – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour de plus amples informations, veuillez consulter [Expressions](#).

Exemple : vérification du nombre de lignes par rapport à un jeu de données de référence

L'exemple de règle suivant vérifie si le nombre de lignes du jeu de données principal est au moins égal à 90 % du nombre de lignes du jeu de données de référence.

```
RowCountMatch "reference" >= 0.9
```

StandardDeviation

Vérifie l'écart type de toutes les valeurs d'une colonne par rapport à une expression donnée.

Syntaxe

```
StandardDeviation <COL_NAME> <EXPRESSION>
```

- **COL_NAME** – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- **EXPRESSION** – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour plus d'informations, consultez [Expressions](#).

Exemple : écart type

L'exemple de règle suivant vérifie si l'écart type des valeurs d'une colonne nommée colA est inférieur à une valeur spécifiée.

```
StandardDeviation "Star_Rating" < 1.5
StandardDeviation "Salary" < 3500 where "Customer_ID < 10"
```

Exemples de règles dynamiques

- `StandardDeviation "colA" > avg(last(10)) + 0.1`
- `StandardDeviation "colA" between min(last(10)) - 1 and max(last(10)) + 1`

Comportement nul

La `StandardDeviation` règle ignorera les lignes contenant NULL des valeurs dans le calcul de l'écart type. Par exemple :

id	units1	units2
100	0	0
101	null	0
102	20	20
103	null	0
104	40	40

L'écart type de la colonne ne `units1` tiendra pas compte des lignes 101 et 103 et aboutira à 16,33. L'écart type pour la colonne `units2` sera de 16.

Somme

Vérifie la somme de toutes les valeurs d'une colonne par rapport à une expression donnée.

Syntaxe

```
Sum <COL_NAME> <EXPRESSION>
```

- COL_NAME – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- EXPRESSION – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour plus d'informations, consultez [Expressions](#).

Exemple : somme

L'exemple de règle suivant vérifie si la somme de toutes les valeurs d'une colonne dépasse un seuil donné.

```
Sum "transaction_total" > 500000
Sum "Salary" < 55600 where "Customer_ID < 10"
```

Exemples de règles dynamiques

- Sum "ColA" > avg(last(10))
- Sum "colA" between min(last(10)) - 1 and max(last(10)) + 1

Comportement nul

La Sum règle ignorera les lignes contenant des NULL valeurs dans le calcul de la somme. Par exemple :

```
+---+-----+
|id |units   |
+---+-----+
|100|0       |
|101|null   |
|102|20     |
|103|null   |
|104|40     |
+---+-----+
```

La somme des colonnes ne units tiendra pas compte des lignes 101 et 103 et donnera $(0 + 20 + 40) = 60$.

SchemaMatch

Vérifie si le schéma du jeu de données principal correspond au schéma d'un jeu de données de référence. La vérification du schéma s'effectue colonne par colonne. Le schéma de deux colonnes correspond si les noms et les types sont identiques. L'ordre des colonnes n'importe pas.

Syntaxe

```
SchemaMatch <REFERENCE_DATASET_ALIAS> <EXPRESSION>
```

- **REFERENCE_DATASET_ALIAS** : alias du jeu de données de référence par rapport auquel comparer les schémas.

Types de colonnes pris en charge : octet, décimal, double, virgule flottante, entier, long, court

- **EXPRESSION** – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour de plus amples informations, veuillez consulter [Expressions](#).

Exemple : SchemaMatch

L'exemple de règle suivant vérifie si le schéma du jeu de données principal correspond exactement au schéma d'un jeu de données de référence.

```
SchemaMatch "reference" = 1.0
```

Unicité

Vérifie le pourcentage de valeurs uniques dans une colonne par rapport à une expression donnée. Les valeurs uniques n'apparaissent qu'une seule fois.

Syntaxe

```
Uniqueness <COL_NAME> <EXPRESSION>
```

- **COL_NAME** – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : n'importe quel type de colonne

- **EXPRESSION** – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour de plus amples informations, veuillez consulter [Expressions](#).

Exemple

L'exemple de règle suivant vérifie si le pourcentage de valeurs uniques d'une colonne correspond à certains critères numériques.

```
Uniqueness "email" = 1.0  
Uniqueness "Customer_ID" != 1.0 where "Customer_ID" < 10
```

L'exemple de règle suivant vérifie plusieurs colonnes.

```
Uniqueness "vendorid" "tpep_pickup_datetime" = 1
```

Exemples de règles dynamiques

- `Uniqueness "colA" between min(last(10)) and max(last(10))`
- `Uniqueness "colA" >= avg(last(10))`

UniqueValueRatio

Vérifie le ratio de valeurs uniques d'une colonne par rapport à une expression donnée. Un ratio de valeurs uniques correspond à la fraction de valeurs uniques divisée par le nombre de toutes les valeurs distinctes d'une colonne. Les valeurs uniques n'apparaissent qu'une seule fois, alors que les valeurs distinctes apparaissent au moins une fois.

Par exemple, le jeu `[a, a, b]` contient une valeur unique (`b`) et deux valeurs distinctes (`a` et `b`). Le ratio de valeurs uniques du jeu est donc $\frac{1}{2} = 0,5$.

Syntaxe

```
UniqueValueRatio <COL_NAME> <EXPRESSION>
```

- **COL_NAME** – Nom de la colonne par rapport à laquelle la règle de qualité des données doit être évaluée.

Types de colonnes pris en charge : n'importe quel type de colonne

- **EXPRESSION** – Expression à exécuter en fonction de la réponse du type de règle afin de produire une valeur booléenne. Pour de plus amples informations, veuillez consulter [Expressions](#).

Exemple : ratio de valeurs uniques

Cet exemple vérifie le ratio de valeurs uniques d'une colonne par rapport à une plage de valeurs.

```
UniqueValueRatio "test_score" between 0 and 0.5  
UniqueValueRatio "Customer_ID" between 0 and 0.9 where "Customer_ID < 10"
```

Exemples de règles dynamiques

- `UniqueValueRatio "colA" > avg(last(10))`
- `UniqueValueRatio "colA" <= index(last(10),2) + std(last(5))`

DetectAnomalies

Détecte les anomalies pour une règle de qualité des données donnée. Chaque exécution d'une DetectAnomalies règle entraîne l'enregistrement de la valeur évaluée pour la règle donnée. Lorsque suffisamment de données sont collectées, l'algorithme de détection des anomalies prend toutes les données historiques pour cette règle donnée et exécute la détection des anomalies. DetectAnomalies la règle échoue lorsqu'une anomalie est détectée. Plus d'informations sur l'anomalie détectée peuvent être obtenues à partir des observations.

Syntaxe

```
DetectAnomalies <RULE_NAME> <RULE_PARAMETERS>
```

RULE_NAME : le nom de la règle pour laquelle vous souhaitez évaluer et détecter des anomalies.

Règles prises en charge :

- "RowCount"
- "Completeness"
- "Uniqueness"

- "Mean"
- "Sum"
- "StandardDeviation"
- "Entropy"
- "DistinctValuesCount"
- "UniqueValueRatio"
- "ColumnLength"
- "ColumnValues"
- "ColumnCorrelation"
- « SQL personnalisé »
- "ColumnCount"

RULE_PARAMETERS : certaines règles nécessitent des paramètres supplémentaires pour s'exécuter. Reportez-vous à la documentation de la règle concernée pour connaître les paramètres requis.

Exemple : Anomalies pour RowCount

Par exemple, si nous voulons détecter des RowCount anomalies, nous indiquons RowCount le nom de la règle.

```
DetectAnomalies "RowCount"
```

Exemple : Anomalies pour ColumnLength

Par exemple, si nous voulons détecter des ColumnLength anomalies, nous indiquons le nom de la ColumnLength règle et le nom de la colonne.

```
DetectAnomalies "ColumnLength" "id"
```

FileFreshness

FileFreshness garantit que vos fichiers de données sont à jour en fonction de l'état que vous fournissez. Il utilise l'heure de dernière modification de vos fichiers pour garantir que les fichiers de données ou l'ensemble du dossier le sont up-to-date.

Cette règle regroupe deux indicateurs :

- FileFreshness conformité en fonction de la règle que vous avez définie
- Le nombre de fichiers scannés selon la règle

```
{"Dataset.*.FileFreshness.Compliance":1,"Dataset.*.FileCount":1}
```

La détection des anomalies ne prend pas en compte ces métriques.

Vérification de la fraîcheur des fichiers

La règle suivante garantit que tickets.parquet a été créé au cours des dernières 24 heures.

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/tickets.parquet" >
(now() - 24 hours)
```

Vérification de la fraîcheur du dossier

La règle suivante s'applique si tous les fichiers du dossier ont été créés ou modifiés au cours des dernières 24 heures.

```
FileFreshness "s3://bucket/" >= (now() - 1 days)
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" >= (now() - 24 hours)
```

Vérification de la fraîcheur d'un dossier ou d'un fichier avec un seuil

La règle suivante est applicable si 10 % des fichiers du dossier « tickets » ont été créés ou modifiés au cours des 10 derniers jours.

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" < (now() - 10 days)
with threshold > 0.1
```

Vérification de fichiers ou de dossiers avec des dates spécifiques

Vous pouvez vérifier la fraîcheur du fichier pour des jours spécifiques.

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > "2020-01-01"
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between "2023-01-01"
and "2024-01-01"
```

Vérification des fichiers ou des dossiers avec le temps

Vous pouvez l'utiliser FileFreshness pour vous assurer que les fichiers sont arrivés à certaines heures.

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between now() and  
(now() - 45 minutes)  
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between "9:30 AM" and  
"9:30 PM"  
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > (now() - 10 minutes)  
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > now()  
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between (now() - 2  
hours) and (now() + 15 minutes)  
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between (now() - 3  
days) and (now() + 15 minutes)  
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between "2001-02-07"  
and (now() + 15 minutes)  
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > "21:45"  
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > "2024-01-01"  
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between "02:30" and  
"04:30"  
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between "9:30 AM" and  
"22:15"
```

Considérations clés :

- FileFreshness peut évaluer les fichiers en utilisant des unités de jours, d'heures et de minutes
- Parfois, il prend en charge le matin, le soir et 24 heures sur 24
- Les heures sont calculées en UTC sauf si une dérogation est spécifiée
- Les dates sont calculées en UTC à l'heure 00:00

FileFreshness qui sont basés sur le temps fonctionnent comme suit :

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > "21:45"
```

- Tout d'abord, l'heure « 21:45 » est combinée avec la date du jour au format UTC pour créer un champ date-heure
- Ensuite, la date-heure est convertie en un fuseau horaire que vous avez spécifié
- Enfin, la règle est évaluée

Balises de règles facultatives basées sur des fichiers :

Les balises vous permettent de contrôler le comportement des règles.

Dossiers récents

Cette balise limite le nombre de fichiers traités en conservant le fichier le plus récent en premier.

```
FileFreshness "s3://amzn-s3-demo-bucket/" between (now() - 100 minutes) and (now() + 10 minutes) with recentFiles = 1
```

Fuseau horaire

Dérogations de fuseau horaire acceptées, voir Fuseaux horaires [autorisés pour connaître les fuseaux horaires](#) pris en charge.

```
FileFreshness "s3://path/" > "21:45" with timeZone = "America/New_York"
```

```
FileFreshness "s3://path/" > "21:45" with timeZone = "America/Chicago"
```

```
FileFreshness "s3://path/" > "21:45" with timeZone = "Europe/Paris"
```

```
FileFreshness "s3://path/" > "21:45" with timeZone = "Asia/Shanghai"
```

```
FileFreshness "s3://path/" > "21:45" with timeZone = "Australia/Darwin"
```

Déduire des noms de fichiers directement à partir de trames de données

Il n'est pas toujours nécessaire de fournir un chemin de fichier. Par exemple, lorsque vous créez la règle dans le catalogue de données AWS Glue, il peut être difficile de trouver les dossiers utilisés par les tables du catalogue. AWS Glue Data Quality peut trouver les dossiers ou fichiers spécifiques utilisés pour remplir votre dataframe et détecter s'ils sont récents.


Note

Cette fonctionnalité ne fonctionne que lorsque les fichiers sont correctement lus dans le DynamicFrame ou DataFrame.

```
FileFreshness > (now() - 24 hours)
```

Cette règle permet de trouver le chemin du dossier ou les fichiers utilisés pour remplir le cadre dynamique ou le bloc de données. Cela fonctionne pour les chemins Amazon S3 ou pour les tables AWS Glue Data Catalog basées sur Amazon S3. Il y a quelques considérations à prendre en compte :

1. Dans AWS Glue ETL, vous devez disposer de la `EvaluateDataQuality` transformation immédiatement après une transformation d'Amazon S3 ou de AWS Glue Data Catalog.



2. Cette règle ne fonctionnera pas dans les sessions AWS Glue Interactive.

Si vous essayez de le faire dans les deux cas, ou si AWS Glue ne trouve pas les fichiers, AWS Glue générera le message d'erreur suivant : "Unable to parse file path from DataFrame"

FileMatch

La FileMatch règle vous permet de comparer des fichiers à d'autres fichiers ou à des checksums. Cela peut être utile dans certains scénarios :

1. Validation des fichiers reçus de sources externes : vous pouvez vous FileMatch assurer que vous avez reçu les bons fichiers provenant de sources externes en les comparant aux sommes de contrôle. Cela permet de valider l'intégrité des données que vous ingérez.
2. Comparaison de données dans deux dossiers différents : FileMatch peut être utilisé pour comparer des fichiers entre deux dossiers.

Cette règle regroupe une métrique : le nombre de fichiers analysés par la règle.

```
{"Dataset.*.FileCount":1}
```

Validez le fichier avec une somme de contrôle :

FileMatch accepte un fichier et une somme de contrôle définie pour s'assurer qu'au moins une somme de contrôle correspond au fichier.

```
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac041793154713e5ef8f319"]  
  with hashAlgorithm = "MD5"  
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac041793154713e5ef8f319"]  
  with hashAlgorithm = "SHA-1"  
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac041793154713e5ef8f319"]  
  with hashAlgorithm = "SHA-256"  
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac041793154713e5ef8f319"]
```

Les algorithmes standard suivants sont pris en charge :

- MD5
- SHA-1
- SHA-256

Si vous ne fournissez aucun algorithme, la valeur par défaut est SHA-256.

Validez tous les fichiers d'un dossier avec un ensemble de checksum :

```
FileMatch "s3://amzn-s3-demo-bucket /" in ["3ee0d8617ac041793154713e5ef8f319",  
  "7e8617ac041793154713e5ef8f319"] with hashAlgorithm = "MD5"  
FileMatch "s3://amzn-s3-demo-bucket /internal-folder/" in  
  ["3ee0d8617ac041793154713e5ef8f319", "7e8617ac041793154713e5ef8f319"]
```

Comparer des fichiers dans différents dossiers

```
FileMatch "s3://original_bucket/" "s3://archive_bucket/"  
FileMatch "s3://original_bucket/internal-folder/" "s3://original_bucket/other-folder/"
```

FileMatch vérifiera le contenu des fichiers `original_bucket` et s'assurera qu'ils correspondent à ce qu'ils contiennent `archive_bucket`. La règle échouera si elles ne correspondent pas exactement. Il peut également vérifier le contenu de dossiers internes ou de fichiers individuels.

FileMatch peut également vérifier les fichiers individuels les uns par rapport aux autres.

```
FileMatch "s3://amzn-s3-demo-bucket /file_old.json" "s3://amzn-s3-demo-bucket /file_new.json"
```

Déduire des noms de fichiers directement à partir de trames de données

Il n'est pas toujours nécessaire de fournir un chemin de fichier. Par exemple, lorsque vous créez la règle dans le catalogue de données AWS Glue (soutenu par Amazon S3), il peut être difficile de trouver les dossiers utilisés par les tables du catalogue. AWS Glue Data Quality peut trouver les dossiers ou fichiers spécifiques utilisés pour remplir votre bloc de données.

Note

Cette fonctionnalité ne fonctionne que lorsque les fichiers sont correctement lus dans le DynamicFrame ou DataFrame.

```
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"] with hashAlgorithm = "MD5"
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"] with hashAlgorithm = "SHA-1"
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"] with hashAlgorithm = "SHA-256"
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"]
```

Si la somme de contrôle fournie est différente de celle calculée, elle vous FileMatch avertira de la différence.

Rules (1)

Statistics (0)

Anomalies (0)

Rules (1) Info

Data quality conditions and results.

Filter data quality rule results

Rules	DQ status
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"]	⊗ Rule failed FileMatch - Checksum for file: s3://sompom-fake-bucket/debug_1.json using algorithm SHA-256 was not found in the checksum list. Computed checksum: 65a963c35fb2fb3318b034a0d3eefd71f6b0448b6446f1616cb31fc9b459c3d5 3e5ef8f319"]

Balises de règles facultatives basées sur des fichiers :

Les balises vous permettent de contrôler le comportement des règles.

Fichiers récents

Cette balise limite le nombre de fichiers traités en conservant le fichier le plus récent en premier.

```
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac04179sam4713e5ef8f319"]
with recentFiles = 1
```

matchFileName

Cette balise garantit que les fichiers ne comportent pas de noms dupliqués. Le comportement par défaut est faux.

```
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac04179sam4713e5ef8f319"]
with matchFileName = "true"
```

Il y a quelques considérations à prendre en compte :

1. Dans AWS Glue ETL, vous devez disposer de la `EvaluateDataQuality` transformation immédiatement après une transformation d'Amazon S3 ou de AWS Glue Data Catalog.

The screenshot displays the AWS Glue console interface. On the left, a workflow diagram shows a 'Data source - S3 bucket Amazon S3' node connected to a 'Transform - Evaluate Data Quality' node. The 'Transform' configuration panel on the right shows the 'Name' as 'Evaluate Data Quality' and 'Node parents' as 'Amazon S3'. The 'Ruleset editor' tab is active, showing a sample rule: `FileMatch in ["3ee0d8617ac041793154713e5ef8f319"]`. The bottom of the console shows the 'Output schema' section with a 'READY' status and a 'Loading data previews' progress bar.

2. Cette règle ne fonctionnera pas dans les sessions AWS Glue Interactive.

FileUniqueness

L'unicité des fichiers vous permet de vous assurer qu'il n'y a pas de doublons dans les données que vous avez reçues de vos producteurs de données.

Il rassemble les statistiques de données suivantes :

1. Le nombre de fichiers scannés selon la règle
2. Le taux d'unicité des fichiers

```
Dataset.*.FileUniquenessRatio: 1.00, Dataset.*.FileCount: 8.00
```

Rechercher des fichiers dupliqués dans un dossier :

```
FileUniqueness "s3://bucket/" > 0.5  
FileUniqueness "s3://bucket/folder/" = 1
```

Déduire les noms de dossiers directement à partir des blocs de données pour détecter les doublons :

Il n'est pas toujours nécessaire de fournir un chemin de fichier. Par exemple, lorsque vous créez la règle dans le catalogue de données AWS Glue, il peut être difficile de trouver les dossiers utilisés par les tables du catalogue. AWS Glue Data Quality peut trouver les dossiers ou fichiers spécifiques utilisés pour remplir votre bloc de données.

Note

Lors de l'utilisation de l'inférence, les règles basées sur les fichiers peuvent uniquement détecter les fichiers lus avec succès dans le `DynamicFrame` ou `DataFrame`.

```
FileUniqueness > 0.5
```

Balises de règles facultatives basées sur des fichiers :

Les balises vous permettent de contrôler le comportement des règles.

Dossiers récents

Cette balise limite le nombre de fichiers traités en conservant le fichier le plus récent en premier.

```
FileUniqueness "s3://amzn-s3-demo-bucket/" > 0.5 with recentFiles = 1
```

`matchFileName`

Cette balise garantit que les fichiers ne comportent pas de noms dupliqués. Le comportement par défaut est faux.

```
FileUniqueness "s3://amzn-s3-demo-bucket/" > 0.5 with matchFileName = "true"
```

Il y a quelques considérations à prendre en compte :

1. Dans AWS Glue ETL, vous devez disposer de la `EvaluateDataQuality` transformation immédiatement après une transformation d'Amazon S3 ou de AWS Glue Data Catalog.
2. Cette règle ne fonctionnera pas dans les sessions AWS Glue Interactive.

FileSize

Le `FileSize` type de règle vous permet de vous assurer que les fichiers répondent à certains critères de taille de fichier. Cela est utile pour les cas d'utilisation suivants :

1. Assurez-vous que les producteurs n'envoient pas de fichiers vides ou nettement plus petits pour traitement.
2. Assurez-vous que vos compartiments cibles ne contiennent pas de fichiers plus petits, ce qui pourrait entraîner des problèmes de performances.

`FileSize` rassemble les métriques suivantes :

1. Conformité : renvoie le pourcentage de fichiers qui atteignent le seuil de règle que vous avez établi
2. Nombre de fichiers : nombre de fichiers analysés selon la règle
3. Taille de fichier minimale en octets
4. Taille maximale du fichier en octets

```
Dataset.*.FileSize.Compliance: 1.00,  
Dataset.*.FileCount: 8.00,  
Dataset.*.MaximumFileSize: 327413121.00,  
Dataset.*.MinimumFileSize: 204558920.00
```

La détection des anomalies n'est pas prise en charge pour ces métriques.

Valider la taille des fichiers

Cette règle est acceptée lorsque le fichier file.dat est supérieur à 2 Mo.

```
FileSize "s3://amzn-s3-demo-bucket/file.dat" > 2 MB
```

Les unités prises en charge sont les suivantes : B (octets), Mo (méga-octets), Go (gigaoctets) et To (terra octets).

Valider la taille des fichiers dans les dossiers

```
FileSize "s3://bucket/" > 5 B  
FileSize "s3://bucket/" < 2 GB
```

Cette règle sera acceptée si 70 % des fichiers du site s3://amzn-s3-demo-bucket ont une taille comprise entre 2 Go et 1 To.

```
FileSize "s3://amzn-s3-demo-bucket/" between 2 GB and 1 TB with threshold > 0.7
```

Déduire des noms de fichiers directement à partir de trames de données

Il n'est pas toujours nécessaire de fournir un chemin de fichier. Par exemple, lorsque vous créez la règle dans le catalogue de données, il peut être difficile de trouver les dossiers utilisés par les tables du catalogue. AWS Glue Data Quality peut trouver les dossiers ou fichiers spécifiques utilisés pour remplir votre bloc de données.

Note

Cette fonctionnalité ne fonctionne que lorsque les fichiers sont correctement lus dans le DynamicFrame ou DataFrame.

```
FileSize < 10 MB with threshold > 0.7
```

Balises de règles facultatives basées sur des fichiers :

Les balises vous permettent de contrôler le comportement des règles.

Fichiers récents

Cette balise limite le nombre de fichiers traités en conservant le fichier le plus récent en premier.

```
FileSize "s3://amzn-s3-demo-bucket/" > 5 B with recentFiles = 1
```

matchFileName

Cette balise garantit que les fichiers ne comportent pas de noms dupliqués. Le comportement par défaut est faux.

```
FileSize "s3://amzn-s3-demo-bucket/" > 5 B with matchFileName = "true"
```

Il y a quelques considérations à prendre en compte :

1. Dans AWS Glue ETL, vous devez disposer d' `DataQuality Evaluate Transform` immédiatement après la transformation d'Amazon S3 ou de Data Catalog.
2. Cette règle ne fonctionnera pas dans les sessions AWS Glue Interactive.

Utilisation APIs pour mesurer et gérer la qualité des données

Cette rubrique décrit comment l'utiliser APIs pour mesurer et gérer la qualité des données.

Table des matières

- [Prérequis](#)
- [Utilisation des recommandations relatives à AWS la qualité des données de Glue](#)
- [Travailler avec les ensembles de règles de qualité des données de AWS Glue](#)
- [Travailler avec AWS Glue Data Quality s'exécute](#)
- [Utilisation des résultats AWS de Glue Data Quality](#)

Prérequis

- Assurez-vous que votre version de boto3 est à jour afin d'inclure la dernière API AWS Glue Data Quality.
- Assurez-vous que la version de votre AWS CLI est à jour, afin d'inclure la dernière CLI.

Si vous utilisez une tâche AWS Glue pour les exécuter APIs, vous pouvez utiliser l'option suivante pour mettre à jour la dernière version de la bibliothèque boto3 :

```
-additional-python-modules boto3==<version>
```

Utilisation des recommandations relatives à AWS la qualité des données de Glue

Pour démarrer une recommandation de AWS Glue Data Quality, exécutez :

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def start_data_quality_rule_recommendation_run(self, database_name, table_name,
        role_arn):
        """
        Starts a recommendation run that is used to generate rules when you don't know
        what rules to write. AWS Glue Data Quality
        analyzes the data and comes up with recommendations for a potential ruleset.
        You can then triage the ruleset
        and modify the generated ruleset to your liking.

        :param database_name: The name of the AWS Glue database which contains the
        dataset.
        :param table_name: The name of the AWS Glue table against which we want a
        recommendation
        :param role_arn: The Amazon Resource Name (ARN) of an AWS Identity and Access
        Management (IAM) role that grants permission to let AWS Glue access the resources it
        needs.

        """
        try:
            response = self.client.start_data_quality_rule_recommendation_run(
                DataSource={
                    'GlueTable': {
                        'DatabaseName': database_name,
                        'TableName': table_name
                    }
                },
                Role=role_arn
```

```

    )
except ClientError as err:
    logger.error(
        "Couldn't start data quality recommendation run %s. Here's why: %s:
%s", name,
        err.response['Error']['Code'], err.response['Error']['Message'])
    raise
else:
    return response['RunId']

```

Pour une exécution de recommandation, vous pouvez utiliser vos `pushDownPredicates` ou vos `catalogPartitionPredicates` pour améliorer les performances et exécuter des recommandations uniquement sur des partitions spécifiques de vos sources de catalogue.

```

client.start_data_quality_rule_recommendation_run(
    DataSource={
        'GlueTable': {
            'DatabaseName': database_name,
            'TableName': table_name,
            'AdditionalOptions': {
                'pushDownPredicate': "year=2022"
            }
        }
    },
    Role=role_arn,
    NumberOfWorkers=2,
    CreatedRulesetName='<rule_set_name>'
)

```

Pour obtenir les résultats d'une recommandation de AWS Glue Data Quality, exécutez :

```

class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def get_data_quality_rule_recommendation_run(self, run_id):
        """
        Gets the specified recommendation run that was used to generate rules.

```

```

:param run_id: The id of the data quality recommendation run

"""
try:
    response =
self.client.get_data_quality_rule_recommendation_run(RunId=run_id)
except ClientError as err:
    logger.error(
        "Couldn't get data quality recommendation run %. Here's why: %s: %s",
run_id,
        err.response['Error']['Code'], err.response['Error']['Message'])
    raise
else:
    return response

```

À partir de l'objet de réponse ci-dessus, vous pouvez extraire celui RuleSet qui a été recommandé par l'exécution, pour l'utiliser dans les étapes suivantes :

```

print(response['RecommendedRuleset'])

Rules = [
    RowCount between 2000 and 8000,
    IsComplete "col1",
    IsComplete "col2",
    StandardDeviation "col3" between 58138330.8 and 64258155.09,
    ColumnValues "col4" between 1000042965 and 1214474826,
    IsComplete "col5"
]

```

Pour obtenir une liste de toutes vos exécutions de recommandation qui peuvent être filtrées et répertoriées :

```

response = client.list_data_quality_rule_recommendation_runs(
    Filter={
        'DataSource': {
            'GlueTable': {
                'DatabaseName': '<database_name>',
                'TableName': '<table_name>'
            }
        }
    }
)

```


Pour annuler les tâches de recommandation de AWS Glue Data Quality existantes, procédez comme suit :

```
response = client.cancel_data_quality_rule_recommendation_run(  
    RunId='dqr-un-d4b6b01957fdd79e59866365bf9cb0e40fxxxxxxx'  
)
```

Travailler avec les ensembles de règles de qualité des données de AWS Glue

Pour créer un ensemble de règles AWS Glue Data Quality, procédez comme suit :

```
response = client.create_data_quality_ruleset(  
    Name='<ruleset_name>',  
    Ruleset='Rules = [IsComplete "col1", IsPrimaryKey "col2", RowCount between 2000 and  
8000]',  
    TargetTable={  
        'TableName': '<table_name>',  
        'DatabaseName': '<database_name>'  
    }  
)
```

Pour obtenir un ensemble de règles de qualité des données :

```
response = client.get_data_quality_ruleset(  
    Name='<ruleset_name>'  
)  
print(response)
```

Vous pouvez utiliser cette API pour ensuite extraire l'ensemble de règles :

```
print(response['Ruleset'])
```

Pour répertorier tous les ensembles de règles de qualité des données pour une table :

```
response = client.list_data_quality_rulesets()
```

Vous pouvez utiliser la condition de filtrage dans l'API pour filtrer tous les ensembles de règles attachés à une base de données ou à une table spécifique :

```
response = client.list_data_quality_rulesets(
    Filter={
        'TargetTable': {
            'TableName': '<table_name>',
            'DatabaseName': '<database_name>'
        }
    },
)
```

Pour mettre à jour un ensemble de règles de qualité des données :

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def update_data_quality_ruleset(self, ruleset_name, ruleset_string):
        """
        Update an AWS Glue Data Quality Ruleset

        :param ruleset_name: The name of the AWS Glue Data Quality ruleset to update
        :param ruleset_string: The DQDL ruleset string to update the ruleset with

        """
        try:
            response = self.client.update_data_quality_ruleset(
                Name=ruleset_name,
                Ruleset=ruleset_string
            )
        except ClientError as err:
            logger.error(
                "Couldn't update the AWS Glue Data Quality ruleset. Here's why: %s:
%s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response
```

Pour supprimer un ensemble de règles de qualité des données :

```

class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def delete_data_quality_ruleset(self, ruleset_name):
        """
        Delete a AWS Glue Data Quality Ruleset

        :param ruleset_name: The name of the AWS Glue Data Quality ruleset to delete

        """
        try:
            response = self.client.delete_data_quality_ruleset(
                Name=ruleset_name
            )
        except ClientError as err:
            logger.error(
                "Couldn't delete the AWS Glue Data Quality ruleset. Here's why: %s:
%s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response

```

Travailler avec AWS Glue Data Quality s'exécute

Pour démarrer une exécution de AWS Glue Data Quality, procédez comme suit :

```

class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def start_data_quality_ruleset_evaluation_run(self, database_name, table_name,
role_name, ruleset_list):
        """

```

Start an AWS Glue Data Quality evaluation run

:param database_name: The name of the AWS Glue database which contains the dataset.

:param table_name: The name of the AWS Glue table against which we want to evaluate.

:param role_arn: The Amazon Resource Name (ARN) of an AWS Identity and Access Management (IAM) role that grants permission to let AWS Glue access the resources it needs.

:param ruleset_list: The list of AWS Glue Data Quality ruleset names to evaluate.

```

"""
try:
    response = client.start_data_quality_ruleset_evaluation_run(
        DataSource={
            'GlueTable': {
                'DatabaseName': database_name,
                'TableName': table_name
            }
        },
        Role=role_name,
        RulesetNames=ruleset_list
    )
except ClientError as err:
    logger.error(
        "Couldn't start the AWS Glue Data Quality Run. Here's why: %s: %s",
        err.response['Error']['Code'], err.response['Error']['Message'])
    raise
else:
    return response['RunId']

```

N'oubliez pas que vous pouvez transmettre un paramètre `pushDownPredicate` ou `catalogPartitionPredicate` pour garantir que votre exécution de qualité des données ne cible qu'un ensemble spécifique de partitions dans votre table de catalogue. Par exemple :

```

response = client.start_data_quality_ruleset_evaluation_run(
    DataSource={
        'GlueTable': {
            'DatabaseName': '<database_name>',
            'TableName': '<table_name>',
            'AdditionalOptions': {
                'pushDownPredicate': 'year=2023'
            }
        }
    )

```

```

        }
    }
},
Role='<role_name>',
NumberOfWorkers=5,
Timeout=123,
AdditionalRunOptions={
    'CloudWatchMetricsEnabled': False
},
RulesetNames=[
    '<ruleset_name>',
]
)

```

Vous pouvez également configurer la manière dont les règles composites de votre ensemble de règles sont évaluées, au niveau de la LIGNE ou de la COLONNE. Pour plus d'informations sur le fonctionnement des règles composites, reportez-vous à la section [Fonctionnement des règles composites](#) dans la documentation.

Exemple expliquant comment définir la méthode d'évaluation des règles composites dans votre demande :

```

response = client.start_data_quality_ruleset_evaluation_run(
    DataSource={
        'GlueTable': {
            'DatabaseName': '<database_name>',
            'TableName': '<table_name>',
            'AdditionalOptions': {
                'pushDownPredicate': 'year=2023'
            }
        }
    },
    Role='<role_name>',
    NumberOfWorkers=5,
    Timeout=123,
    AdditionalRunOptions={
        'CompositeRuleEvaluationMethod': ROW
    },
    RulesetNames=[
        '<ruleset_name>',
    ]
)

```

Pour obtenir des informations sur un AWS Glue Data Quality, exécutez :

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def get_data_quality_ruleset_evaluation_run(self, run_id):
        """
        Get details about an AWS Glue Data Quality Run

        :param run_id: The AWS Glue Data Quality run ID to look up
        """
        try:
            response = self.client.get_data_quality_ruleset_evaluation_run(
                RunId=run_id
            )
        except ClientError as err:
            logger.error(
                "Couldn't look up the AWS Glue Data Quality run ID. Here's why: %s:
%s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response
```

Pour obtenir les résultats d'une exécution de AWS Glue Data Quality :

Pour une exécution de AWS Glue Data Quality donnée, vous pouvez extraire les résultats de l'évaluation de l'exécution à l'aide de la méthode suivante :

```
response = client.get_data_quality_ruleset_evaluation_run(
    RunId='d4b6b01957fdd79e59866365bf9cb0e40fxxxxxxx'
)

resultID = response['ResultIds'][0]

response = client.get_data_quality_result(
    ResultId=resultID
```

```
)

print(response['RuleResults'])
```

Pour répertorier toutes vos exécutions de AWS Glue Data Quality, procédez comme suit :

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def list_data_quality_ruleset_evaluation_runs(self, database_name, table_name):
        """
        Lists all the AWS Glue Data Quality runs against a given table

        :param database_name: The name of the database where the data quality runs
        :param table_name: The name of the table against which the data quality runs
        were created

        """
        try:
            response = self.client.list_data_quality_ruleset_evaluation_runs(
                Filter={
                    'DataSource': {
                        'GlueTable': {
                            'DatabaseName': database_name,
                            'TableName': table_name
                        }
                    }
                }
            )
        except ClientError as err:
            logger.error(
                "Couldn't list the AWS Glue Quality runs. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response
```

Vous pouvez modifier la clause de filtrage pour n'afficher que les résultats obtenus à des moments précis ou concernant des tables spécifiques.

Pour arrêter une exécution de AWS Glue Data Quality en cours :

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def cancel_data_quality_ruleset_evaluation_run(self, result_id):
        """
        Cancels a given AWS Glue Data Quality run

        :param result_id: The result id of a AWS Glue Data Quality run to cancel

        """
        try:
            response = self.client.cancel_data_quality_ruleset_evaluation_run(
                ResultId=result_id
            )
        except ClientError as err:
            logger.error(
                "Couldn't cancel the AWS Glue Data Quality run. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response
```

Utilisation des résultats AWS de Glue Data Quality

Pour obtenir les résultats de votre exécution avec AWS Glue Data Quality, procédez comme suit :

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client
```



```
def get_data_quality_result(self, result_id):
    """
    Outputs the result of an AWS Glue Data Quality Result

    :param result_id: The result id of an AWS Glue Data Quality run

    """
    try:
        response = self.client.get_data_quality_result(
            ResultId=result_id
        )
    except ClientError as err:
        logger.error(
            "Couldn't get the AWS Glue Data Quality result. Here's why: %s: %s",
            err.response['Error']['Code'], err.response['Error']['Message'])
        raise
    else:
        return response
```

Pour consulter les statistiques recueillies pour un résultat de qualité des données donné, procédez comme suit :

```
import boto3
from botocore.exceptions import ClientError
import logging

logger = logging.getLogger(__name__)
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def get_profile_for_data_quality_result(self, result_id):
        """
        Outputs the statistic profile for a AWS Glue Data Quality Result

        :param result_id: The result id of a AWS Glue Data Quality run

        """
```

```

try:
    response = self.glue_client.get_data_quality_result(
        ResultId=result_id
    )

    # the profile contains all statistics gathered for the result
    profile_id = response['ProfileId']
    profile = self.glue_client.list_data_quality_statistics(
        ProfileId = profile_id
    )
    return profile
except ClientError as err:
    logger.error(
        "Couldn't retrieve Data Quality profile. Here's why: %s: %s",
        err.response['Error']['Code'], err.response['Error']['Message'])
    raise

```

Pour consulter les séries chronologiques d'une statistique collectée au cours de plusieurs cycles de qualité des données, procédez comme suit :

```

class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def get_statistics_for_data_quality_result(self, profile_id):
        """
        Outputs an array of datapoints for each statistic in the input result.

        :param result_id: The profile id of a AWS Glue Data Quality run

        """
        try:
            profile = self.glue_client.list_data_quality_statistics(
                ProfileId = profile_id
            )
            statistics = [self.glue_client.list_data_quality_statistics(
                StatisticId = s['StatisticId']
            ) for s in profile['Statistics']]
            return statistics

```

```
except ClientError as err:
    logger.error(
        "Couldn't retrieve Data Quality statistics. Here's why: %s: %s",
        err.response['Error']['Code'], err.response['Error']['Message'])
    raise
```

Pour consulter le modèle de détection des anomalies pour une statistique spécifique, procédez comme suit :

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def get_model_training_result_for_statistic(self, statistic_id, profile_id):
        """
        Outputs the details (bounds) of anomaly detection training for the given
        statistic at the given profile.

        :param statistic_id the model's statistic (the timeseries it is tracking)
        :param profile_id the profile associated with the model (a point in the
        timeseries)

        """
        try:
            model = self.glue_client.get_data_quality_model_result(
                ProfileId = profile_id, StatisticId = statistic_id
            )
            return model
        except ClientError as err:
            logger.error(
                "Couldn't retrieve Data Quality model results. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
```

Pour exclure un point de données de la ligne de base de détection des anomalies de son modèle statistique, procédez comme suit :

```
class GlueWrapper:
```

```

"""Encapsulates AWS Glue actions."""
def __init__(self, glue_client):
    """
    :param glue_client: A Boto3 AWS Glue client.
    """
    self.glue_client = glue_client

def apply_exclusions_to_statistic(self, statistic_id, profile_ids):
    """
    Annotate some points along a given statistic timeseries.

    This example excludes the provided values; INCLUDE can also be used to undo
    this action.

    :param statistic_id the statistic timeseries to annotate
    :param profile_id the profiles we want to exclude (points in the timeseries)

    """

    try:
        response = self.glue_client.batch_put_data_quality_statistic_annotation(
            InclusionAnnotations = [
                {'ProfileId': prof_id,
                 'StatisticId': statistic_id,
                 'InclusionAnnotation': 'EXCLUDE'} for prof_id in profile_ids
            ]
        )
        return response['FailedInclusionAnnotations']
    except ClientError as err:
        logger.error(
            "Couldn't store Data Quality annotations. Here's why: %s: %s",
            err.response['Error']['Code'], err.response['Error']['Message'])
        raise

```

Pour consulter l'état de l'entraînement du modèle de détection des anomalies pour une statistique spécifique, procédez comme suit :

```

class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """

```

```

        self.glue_client = glue_client

    def get_model_training_status_for_statistic(self, statistic_id, profile_id):
        """
        Outputs the status of anomaly detection training for the given statistic at the
        given profile.

        :param statistic_id the model's statistic (the timeseries it is tracking)
        :param profile_id the profile associated with the model (a point in the
        timeseries)

        """
        try:
            model = self.glue_client.get_data_quality_model(
                ProfileId = profile_id, StatisticId = statistic_id
            )
            return model
        except ClientError as err:
            logger.error(
                "Couldn't retrieve Data Quality statistics. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise

```

Pour exclure tous les résultats d'une analyse de qualité des données spécifique des lignes de base de détection des anomalies :

```

class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def apply_exclusions_to_profile(self, profile_id):
        """
        Exclude datapoints produced by a run across statistic timeseries.

        This example excludes the provided values; INCLUDE can also be used to undo
        this action.

        :param profile_id the profiles we want to exclude (points in the timeseries)

```

```

"""
try:
    response = self.glue_client.put_data_quality_profile_annotation(
        ProfileId = profile_id,
        InclusionAnnotation = "EXCLUDE"
    )
    return response
except ClientError as err:
    logger.error(
        "Couldn't store Data Quality annotations. Here's why: %s: %s",
        err.response['Error']['Code'], err.response['Error']['Message'])
    raise

```

Pour obtenir les résultats d'une analyse de qualité des données donnée et afficher les résultats :

Avec une AWS Glue Data QualityrunID, vous pouvez les extraire resultID pour obtenir les résultats réels, comme indiqué ci-dessous :

```

response = client.get_data_quality_ruleset_evaluation_run(
    RunId='dqrun-abca77ee126abe1378c1da1ae0750d7dxxxx'
)

resultID = response['ResultIds'][0]

response = client.get_data_quality_result(
    ResultId=resultID
)

print(resp['RuleResults'])

```

Configuration des alertes, des déploiements et de la planification

Cette rubrique explique comment configurer les alertes, les déploiements et la planification pour AWS Glue Data Quality.

Table des matières

- [Configuration des alertes et des notifications dans le cadre de EventBridge l'intégration Amazon](#)
 - [Options de configuration supplémentaires pour le modèle d'événement](#)
 - [Formatage des notifications sous forme d'e-mails](#)
- [Configurer des alertes et des notifications lors de l' CloudWatch intégration](#)

- [Interrogation des résultats de la qualité des données pour créer des tableaux de bord](#)
- [Déploiement de règles de qualité des données en utilisant AWS CloudFormation](#)
- [Planification de règles de qualité des données](#)

Configuration des alertes et des notifications dans le cadre de EventBridge l'intégration Amazon

AWS Glue Data Quality prend en charge la publication d' EventBridge événements, qui sont émis à la fin d'une évaluation d'un ensemble de règles de qualité des données. Vous pouvez ainsi facilement configurer des alertes en cas d'échec des règles de qualité des données.

Voici un exemple d'événement lorsque vous évaluez des ensembles de règles de qualité des données dans le catalogue de données. Grâce à ces informations, vous pouvez consulter les données mises à disposition par Amazon EventBridge. Vous pouvez lancer des appels d'API supplémentaires pour obtenir plus de détails. Par exemple, appelez l'API `get_data_quality_result` avec l'ID du résultat pour obtenir les détails d'une exécution particulière.

```
{
  "version": "0",
  "id": "abcdef00-1234-5678-9abc-def012345678",
  "detail-type": "Data Quality Evaluation Results Available",
  "source": "aws.glue-dataquality",
  "account": "123456789012",
  "time": "2017-09-07T18:57:21Z",
  "region": "us-west-2",
  "resources": [],
  "detail": {
    "context": {
      "contextType": "GLUE_DATA_CATALOG",
      "runId": "dqrn-12334567890",
      "databaseName": "db-123",
      "tableName": "table-123",
      "catalogId": "123456789012"
    },
    "resultID": "dqresult-12334567890",
    "rulesetNames": ["rulset1"],
    "state": "SUCCEEDED",
    "score": 1.00,
    "rulesSucceeded": 100,
  }
}
```

```

        "rulesFailed": 0,
        "rulesSkipped": 0
    }
}

```

Voici un exemple d'événement publié lorsque vous évaluez des ensembles de règles de qualité des données dans les blocs-notes AWS Glue ETL ou AWS Glue Studio.

```

{
  "version": "0",
  "id": "abcdef00-1234-5678-9abc-def012345678",
  "detail-type": "Data Quality Evaluation Results Available",
  "source": "aws.glue-dataquality",
  "account": "123456789012",
  "time": "2017-09-07T18:57:21Z",
  "region": "us-west-2",
  "resources": [],
  "detail": {
    "context": {
      "contextType": "GLUE_JOB",
      "jobId": "jr-12334567890",
      "jobName": "dq-eval-job-1234",
      "evaluationContext": "",
    }
    "resultID": "dqresult-12334567890",
    "rulesetNames": ["rulset1"],
    "state": "SUCCEEDED",
    "score": 1.00
    "rulesSucceeded": 100,
    "rulesFailed": 0,
    "rulesSkipped": 0
  }
}

```

Pour que l'évaluation de la qualité des données soit exécutée à la fois dans le catalogue de données et dans les tâches ETL, l' Amazon CloudWatch option Publier les métriques sur, sélectionnée par défaut, doit rester sélectionnée pour que la EventBridge publication fonctionne.

Configuration des EventBridge notifications

Data quality properties

Data quality ruleset

myDataQualityRuleset

Data quality actions

Actions carried out on task run.

☒ Publish metrics to Amazon CloudWatch

Pour recevoir les événements émis et définir des cibles, vous devez configurer les EventBridge règles Amazon. Pour créer des règles :

1. Ouvrez la EventBridge console Amazon.
2. Choisissez Règles dans la section Bus de la barre de navigation.
3. Choisissez Create Rule (Créer une règle).
4. Sous Définir les détails de la règle :
 - a. Pour le nom, saisissez myDQRu1e.
 - b. Saisissez une description (facultatif).
 - c. Pour le bus d'événements, sélectionnez votre bus d'événements. Si vous n'en avez pas, laissez le bus par défaut.
 - d. Pour Type de règle, sélectionnez Règle avec un modèle d'événement, puis choisissez Suivant.
5. Sous Créer un modèle d'événement :
 - a. Pour la source de l'événement, sélectionnez AWS les événements ou les événements EventBridge partenaires.
 - b. Ignorez la section de l'exemple d'événement.
 - c. Pour la méthode de création, sélectionnez Utiliser le formulaire de modèle.
 - d. Pour le modèle d'événement :
 - i. Sélectionnez Services AWS pour Source de l'événement.
 - ii. Sélectionnez Glue Data Quality pour le AWS service.
 - iii. Sélectionnez Résultats de l'évaluation de la qualité des données disponibles pour Type d'événement.
 - iv. Sélectionnez FAILED pour Statuts spécifiques. Vous voyez alors un modèle d'événement similaire à celui présenté ci-dessous :

```
{
  "source": ["aws.glue-dataquality"],
  "detail-type": ["Data Quality Evaluation Results Available"],
  "detail": {
    "state": ["FAILED"]
  }
}
```

- v. Pour plus d'options de configuration, consultez [Options de configuration supplémentaires pour le modèle d'événement](#).

6. Sous Cibles sélectionnées :

- a. Pour Types de cibles, sélectionnez Service AWS .
- b. Utilisez le menu déroulant Sélectionnez une cible pour choisir le AWS service auquel vous souhaitez vous connecter (SNS, Lambda, SQS, etc.), puis choisissez Next.

7. Sous Configurer les balises, cliquez sur Ajouter de nouvelles balises pour ajouter des balises facultatives, puis choisissez Suivant.

8. Une page récapitulative de toutes les sélections s'affiche. Choisissez Créer une règle en bas de la page.

Options de configuration supplémentaires pour le modèle d'événement

En plus de filtrer de votre événement en fonction de sa réussite ou de son échec, vous pouvez également filtrer les événements en fonction de différents paramètres.

Pour ce faire, accédez à la section Modèle d'événement et sélectionnez Modifier le modèle pour spécifier des paramètres supplémentaires. Notez que les champs du modèle d'événements sont sensibles à la casse. Voici des exemples de configuration de modèle d'événement.

Pour capturer les événements d'une table particulière évaluant des ensembles de règles spécifiques, utilisez ce type de modèle :

```
{
  "source": ["aws.glue-dataquality"],
  "detail-type": ["Data Quality Evaluation Results Available"],
  "detail": {
    "context": {
      "contextType": ["GLUE_DATA_CATALOG"],
      "databaseName": "db-123",

```

```
    "tableName": "table-123",
  },
  "rulesetNames": ["ruleset1", "ruleset2"]
  "state": ["FAILED"]
}
}
```

Pour capturer des événements à partir de tâches spécifiques dans l'expérience ETL, utilisez ce type de modèle :

```
{
  "source": ["aws.glue-dataquality"],
  "detail-type": ["Data Quality Evaluation Results Available"],
  "detail": {
    "context": {
      "contextType": ["GLUE_JOB"],
      "jobName": ["dq_evaluation_job1", "dq_evaluation_job2"]
    },
    "state": ["FAILED"]
  }
}
```

Pour capturer les événements dont le score est inférieur à un seuil spécifique (par exemple 70 %) :

```
{
  "source": ["aws.glue-dataquality"],
  "detail-type": ["Data Quality Evaluation Results Available"],
  "detail": {
    "score": [{
      "numeric": ["<=", 0.7]
    }]
  }
}
```

Formatage des notifications sous forme d'e-mails

Vous devez parfois envoyer une notification par e-mail correctement formatée à vos équipes métier. Vous pouvez utiliser Amazon EventBridge et AWS Lambda pour y parvenir.

Glue Data Quality rulesets **Glue_DQ_RULESET_CUSTOM_20de29c13537** run details



AWS Notifications <no-reply@sns.amazonaws.com>

Thursday, 11. May 2023 at 15:01

To: [REDACTED]

Glue Data Quality run details:

```
ruleset_name:  Glue_DQ_RULESET_CUSTOM_20de29c13537
glue_table_name:  devprod_tbl_nxc_taxi_data
glue_database_name:  devprod_db_nyc_taxi_data
run_id:  dqrn-066b41002a56921f9163a4e9156a4f6e20ce47a8
result_id:  dqresult-cd03a2e91c9114b611f6f79363b2288133fc96c0
state:  FAILED
score:  0.5
numRulesSucceeded: 1
numRulesFailed: 1
numRulesSkipped: 0
```

The subject of the email contains the name of the ruleset

Body of email with statistics from the Glue Data Quality Ruleset.

Here are the results of the ruleset evaluation steps

ruleset details evaluation steps results:

Name: Rule_1	Result: PASS	Description: IsComplete "vendorid"	
Name: Rule_2	Result: FAIL	EvaluationMessage: Value: 0.0 does not meet the constraint requirement!	Description:
IsPrimaryKey "vendorid"			

If you wish to stop receiving notifications from this topic, please click or visit the link below to unsubscribe:

[REDACTED] > [https://sns.us-east-1.amazonaws.com/unsubscribe.html?SubscriptionArn=arn:aws:sns:us-east-1:728060703200:SNSSStandardGlueDataQualityBlogAlertNotification:9d82097d-06f6-4c11-951a-3c0e1d9748f2&Endpoint=\[REDACTED\]](https://sns.us-east-1.amazonaws.com/unsubscribe.html?SubscriptionArn=arn:aws:sns:us-east-1:728060703200:SNSSStandardGlueDataQualityBlogAlertNotification:9d82097d-06f6-4c11-951a-3c0e1d9748f2&Endpoint=[REDACTED])

Please do not reply directly to this email. If you have any questions or comments regarding this email, please contact us at <https://aws.amazon.com/support>

L'exemple de code suivant peut être utilisé pour formater vos notifications de qualité des données afin de générer des e-mails.

```
import boto3
import json
from datetime import datetime

sns_client = boto3.client('sns')
glue_client = boto3.client('glue')

sns_topic_arn = 'arn:aws:sns:<region-code>:<account-id>:<sns-topic-name>'

def lambda_handler(event, context):
    log_metadata = {}
```

```

message_text = ""
subject_text = ""

if event['detail']['context']['contextType'] == 'GLUE_DATA_CATALOG':
    log_metadata['ruleset_name'] = str(event['detail']['rulesetNames'][0])
    log_metadata['tableName'] = str(event['detail']['context']['tableName'])
    log_metadata['databaseName'] = str(event['detail']['context']['databaseName'])
    log_metadata['runId'] = str(event['detail']['context']['runId'])
    log_metadata['resultId'] = str(event['detail']['resultId'])
    log_metadata['state'] = str(event['detail']['state'])
    log_metadata['score'] = str(event['detail']['score'])
    log_metadata['numRulesSucceeded'] = str(event['detail']['numRulesSucceeded'])
    log_metadata['numRulesFailed'] = str(event['detail']['numRulesFailed'])
    log_metadata['numRulesSkipped'] = str(event['detail']['numRulesSkipped'])

    message_text += "Glue Data Quality run details:\n"
    message_text += "ruleset_name: {}\n".format(log_metadata['ruleset_name'])
    message_text += "glue_table_name: {}\n".format(log_metadata['tableName'])
    message_text += "glue_database_name: {}\n".format(log_metadata['databaseName'])
    message_text += "run_id: {}\n".format(log_metadata['runId'])
    message_text += "result_id: {}\n".format(log_metadata['resultId'])
    message_text += "state: {}\n".format(log_metadata['state'])
    message_text += "score: {}\n".format(log_metadata['score'])
    message_text += "numRulesSucceeded:
{}\n".format(log_metadata['numRulesSucceeded'])
    message_text += "numRulesFailed: {}\n".format(log_metadata['numRulesFailed'])
    message_text += "numRulesSkipped: {}\n".format(log_metadata['numRulesSkipped'])

    subject_text = "Glue Data Quality ruleset {} run
details".format(log_metadata['ruleset_name'])

else:
    log_metadata['ruleset_name'] = str(event['detail']['rulesetNames'][0])
    log_metadata['jobName'] = str(event['detail']['context']['jobName'])
    log_metadata['jobId'] = str(event['detail']['context']['jobId'])
    log_metadata['resultId'] = str(event['detail']['resultId'])
    log_metadata['state'] = str(event['detail']['state'])
    log_metadata['score'] = str(event['detail']['score'])

    log_metadata['numRulesSucceeded'] = str(event['detail']['numRulesSucceeded'])
    log_metadata['numRulesFailed'] = str(event['detail']['numRulesFailed'])
    log_metadata['numRulesSkipped'] = str(event['detail']['numRulesSkipped'])

    message_text += "Glue Data Quality run details:\n"

```

```

        message_text += "ruleset_name: {}".format(log_metadata['ruleset_name'])
        message_text += "glue_job_name: {}".format(log_metadata['jobName'])
        message_text += "job_id: {}".format(log_metadata['jobId'])
        message_text += "result_id: {}".format(log_metadata['resultId'])
        message_text += "state: {}".format(log_metadata['state'])
        message_text += "score: {}".format(log_metadata['score'])
        message_text += "numRulesSucceeded:
{}".format(log_metadata['numRulesSucceeded'])
        message_text += "numRulesFailed: {}".format(log_metadata['numRulesFailed'])
        message_text += "numRulesSkipped: {}".format(log_metadata['numRulesSkipped'])

        subject_text = "Glue Data Quality ruleset {} run
details".format(log_metadata['ruleset_name'])

        resultID = str(event['detail']['resultId'])
        response = glue_client.get_data_quality_result(ResultId=resultID)
        RuleResults = response['RuleResults']
        message_text += "\n\nruleset details evaluation steps results:\n\n"
        subresult_info = []

        for dic in RuleResults:
            subresult = "Name: {}\t\tResult: {}\t\tDescription: \t{}".format(dic['Name'],
dic['Result'], dic['Description'])
            if 'EvaluationMessage' in dic:
                subresult += "\t\tEvaluationMessage: {}".format(dic['EvaluationMessage'])
            subresult_info.append({
                'Name': dic['Name'],
                'Result': dic['Result'],
                'Description': dic['Description'],
                'EvaluationMessage': dic.get('EvaluationMessage', '')
            })
            message_text += "\n" + subresult

        log_metadata['resultrun'] = subresult_info

        sns_client.publish(
            TopicArn=sns_topic_arn,
            Message=message_text,
            Subject=subject_text
        )

    return {

```

```
'statusCode': 200,  
'body': json.dumps('Message published to SNS topic')  
}
```

Configurer des alertes et des notifications lors de l' CloudWatch intégration

Notre approche recommandée consiste à configurer des alertes relatives à la qualité des données à l'aide d'Amazon EventBridge, car Amazon EventBridge nécessite une configuration unique pour alerter les clients. Cependant, certains clients préfèrent Amazon pour des CloudWatch raisons de familiarité. Pour ces clients, nous proposons une intégration avec Amazon CloudWatch.

Chaque évaluation de la qualité des données de AWS Glue émet une paire de métriques nommées `glue.data.quality.rules.passed` (indiquant le nombre de règles passées) et `glue.data.quality.rules.failed` (indiquant le nombre de règles ayant échoué) par cycle de qualité des données. Vous pouvez utiliser cette métrique émise pour créer des alarmes afin d'avertir les utilisateurs lorsqu'une exécution d'évaluation de la qualité des données se situe en dessous du seuil. Pour commencer à configurer une alarme qui enverrait un e-mail via une notification Amazon SNS, suivez les étapes ci-dessous :

Pour commencer à configurer une alarme qui enverrait un e-mail via une notification Amazon SNS, suivez les étapes ci-dessous :

1. Ouvrez la CloudWatch console Amazon.
2. Choisissez Toutes les métriques sous Métriques. Vous verrez un espace de noms supplémentaire sous Espaces de noms personnalisés nommé qualité des données Glue.

Note

Lorsque vous lancez une AWS analyse de Glue Data Quality, assurez-vous que la CloudWatch case Publish metrics to Amazon est cochée. Dans le cas contraire, les statistiques relatives à cette course en particulier ne seront pas publiées sur Amazon CloudWatch.

Sous l'espace de noms `Glue Data Quality`, vous pouvez voir les métriques émises par table, par ensemble de règles. Dans le cadre de cette rubrique, nous utiliserons la règle `glue.data.quality.rules.failed` et l'alarme si cette valeur est supérieure à 1 (ce qui

signifie que si le nombre d'échecs d'évaluation de la règle est supérieur à 1, nous voulons en être informés).

3. Pour créer l'alarme, sélectionnez Toutes les alarmes sous Alarmes.
4. Choisissez Create alarm (Créer une alerte).
5. Choisissez Sélectionner une métrique.
6. Sélectionnez la métrique `glue.data.quality.rules.failed` correspondant à la table que vous avez créée, puis choisissez Sélectionner une métrique.
7. Sous l'onglet Spécifier les métriques et les conditions, dans la section Métriques :
 - a. Pour Statistics (Statistique), choisissez Sum (Somme).
 - b. Pour Période, choisissez 1 minute.
8. Sous la section Conditions :
 - a. Pour Threshold type (Type de seuil), choisissez Static (Statique).
 - b. Pour Chaque fois que l'échec des règles de qualité des données est..., sélectionnez Supérieur ou égal.
 - c. Pour à..., saisissez 1 comme valeur de seuil.

Ces options impliquent que si la métrique `glue.data.quality.rules.failed` émet une valeur supérieure ou égale à 1, nous déclencherons une alarme. Toutefois, s'il n'y a pas de données, nous les traiterons comme acceptables.

9. Choisissez Suivant.
10. Sous Configurer les actions :
 - a. Pour la section Déclencheur d'état d'alarme, choisissez En alarme.
 - b. Pour la section Envoyer une notification à la rubrique SNS suivante, choisissez Créer une rubrique pour envoyer une notification via une nouvelle rubrique SNS.
 - c. Pour Points de terminaison de l'e-mail qui recevra la notification, saisissez votre adresse e-mail. Cliquez ensuite sur Créer une rubrique.
 - d. Choisissez Suivant.

11. Pour Nom de l'alarme, saisissez `myFirstDQAlarm` et choisissez Suivant.

12. Une page récapitulative de toutes les sélections s'affiche. Choisissez Créer une alarme en bas de la page.

Vous pouvez désormais voir l'alarme en cours de création depuis le tableau de bord des CloudWatch alarmes Amazon.

Interrogation des résultats de la qualité des données pour créer des tableaux de bord

Vous souhaitez peut-être créer un tableau de bord pour afficher vos résultats de qualité de données. Il existe deux façons de procéder :

Configurez Amazon EventBridge avec le code suivant pour écrire les données dans Amazon S3 :

```
import boto3
import json
from datetime import datetime

s3_client = boto3.client('s3')
glue_client = boto3.client('glue')

s3_bucket = 's3-bucket-name'

def write_logs(log_metadata):
    try:
        filename = datetime.now().strftime("%m%d%Y%H%M%S") + ".json"
        key_opts = {
            'year': datetime.now().year,
            'month': "{:02d}".format(datetime.now().month),
            'day': "{:02d}".format(datetime.now().day),
            'filename': filename
        }
        s3key = "gluedataqualitylogs/year={year}/month={month}/day={day}/{filename}".format(**key_opts)
        s3_client.put_object(Bucket=s3_bucket, Key=s3key,
                             Body=json.dumps(log_metadata))
    except Exception as e:
        print(f'Error writing logs to S3: {e}')

def lambda_handler(event, context):
    log_metadata = {}
    message_text = ""
    subject_text = ""

    if event['detail']['context']['contextType'] == 'GLUE_DATA_CATALOG':
        log_metadata['ruleset_name'] = str(event['detail']['rulesetNames'][0])
```

```

log_metadata['tableName'] = str(event['detail']['context']['tableName'])
log_metadata['databaseName'] = str(event['detail']['context']['databaseName'])
log_metadata['runId'] = str(event['detail']['context']['runId'])
log_metadata['resultId'] = str(event['detail']['resultId'])
log_metadata['state'] = str(event['detail']['state'])
log_metadata['score'] = str(event['detail']['score'])
log_metadata['numRulesSucceeded'] = str(event['detail']['numRulesSucceeded'])
log_metadata['numRulesFailed'] = str(event['detail']['numRulesFailed'])
log_metadata['numRulesSkipped'] = str(event['detail']['numRulesSkipped'])

message_text += "Glue Data Quality run details:\n"
message_text += "ruleset_name: {}\n".format(log_metadata['ruleset_name'])
message_text += "glue_table_name: {}\n".format(log_metadata['tableName'])
message_text += "glue_database_name: {}\n".format(log_metadata['databaseName'])
message_text += "run_id: {}\n".format(log_metadata['runId'])
message_text += "result_id: {}\n".format(log_metadata['resultId'])
message_text += "state: {}\n".format(log_metadata['state'])
message_text += "score: {}\n".format(log_metadata['score'])
message_text += "numRulesSucceeded:
{}\n".format(log_metadata['numRulesSucceeded'])
message_text += "numRulesFailed: {}\n".format(log_metadata['numRulesFailed'])
message_text += "numRulesSkipped: {}\n".format(log_metadata['numRulesSkipped'])

subject_text = "Glue Data Quality ruleset {} run
details".format(log_metadata['ruleset_name'])

else:
    log_metadata['ruleset_name'] = str(event['detail']['rulesetNames'][0])
    log_metadata['jobName'] = str(event['detail']['context']['jobName'])
    log_metadata['jobId'] = str(event['detail']['context']['jobId'])
    log_metadata['resultId'] = str(event['detail']['resultId'])
    log_metadata['state'] = str(event['detail']['state'])
    log_metadata['score'] = str(event['detail']['score'])

    log_metadata['numRulesSucceeded'] = str(event['detail']['numRulesSucceeded'])
    log_metadata['numRulesFailed'] = str(event['detail']['numRulesFailed'])
    log_metadata['numRulesSkipped'] = str(event['detail']['numRulesSkipped'])

    message_text += "Glue Data Quality run details:\n"
    message_text += "ruleset_name: {}\n".format(log_metadata['ruleset_name'])
    message_text += "glue_job_name: {}\n".format(log_metadata['jobName'])
    message_text += "job_id: {}\n".format(log_metadata['jobId'])
    message_text += "result_id: {}\n".format(log_metadata['resultId'])
    message_text += "state: {}\n".format(log_metadata['state'])

```

```

        message_text += "score: {}".format(log_metadata['score'])
        message_text += "numRulesSucceeded:
{}".format(log_metadata['numRulesSucceeded'])
        message_text += "numRulesFailed: {}".format(log_metadata['numRulesFailed'])
        message_text += "numRulesSkipped: {}".format(log_metadata['numRulesSkipped'])

        subject_text = "Glue Data Quality ruleset {} run
details".format(log_metadata['ruleset_name'])

        resultID = str(event['detail']['resultId'])
        response = glue_client.get_data_quality_result(ResultId=resultID)
        RuleResults = response['RuleResults']
        message_text += "\n\nruleset details evaluation steps results:\n\n"
        subresult_info = []

        for dic in RuleResults:
            subresult = "Name: {} \t \t Result: {} \t \t Description: \t {}".format(dic['Name'],
dic['Result'], dic['Description'])
            if 'EvaluationMessage' in dic:
                subresult += "\t \t EvaluationMessage: {}".format(dic['EvaluationMessage'])
            subresult_info.append({
                'Name': dic['Name'],
                'Result': dic['Result'],
                'Description': dic['Description'],
                'EvaluationMessage': dic.get('EvaluationMessage', '')
            })
            message_text += "\n" + subresult

        log_metadata['resultrun'] = subresult_info

        write_logs(log_metadata)

    return {
        'statusCode': 200,
        'body': json.dumps('Message published to SNS topic')
    }

```

Après avoir écrit à Amazon S3, vous pouvez utiliser les robots d'exploration AWS Glue pour vous enregistrer auprès d'Athena et interroger les tables.

Configurez un emplacement Amazon S3 lors d'une évaluation de la qualité des données :

Lorsque vous exécutez des tâches de qualité des données dans le AWS Glue Data Catalog ou AWS Glue ETL, vous pouvez fournir un emplacement Amazon S3 pour écrire les résultats de qualité des données sur Amazon S3. Vous pouvez utiliser la syntaxe ci-dessous pour créer une table en référençant la cible afin de lire les résultats de qualité des données.

Notez que vous devez exécuter les requêtes `CREATE EXTERNAL TABLE` et `MSCK REPAIR TABLE` séparément.

```
CREATE EXTERNAL TABLE <my_table_name>(  
    catalogid string,  
    databasename string,  
    tablename string,  
    dqrunid string,  
    evaluationstartedon timestamp,  
    evaluationcompletedon timestamp,  
    rule string,  
    outcome string,  
    failurereason string,  
    evaluatedmetrics string)  
PARTITIONED BY (  
    `year` string,  
    `month` string,  
    `day` string)  
ROW FORMAT SERDE 'org.openx.data.jsonserde.JsonSerDe'  
WITH SERDEPROPERTIES (  
  
    'paths'='catalogId,databaseName,dqRunId,evaluatedMetrics,evaluationCompletedOn,evaluationStart  
STORED AS INPUTFORMAT 'org.apache.hadoop.mapred.TextInputFormat'  
OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'  
LOCATION 's3://glue-s3-dq-bucket-us-east-2-results/'  
TBLPROPERTIES (  
    'classification'='json',  
    'compressionType'='none',  
    'typeOfData'='file');
```

```
MSCK REPAIR TABLE <my_table_name>;
```

Une fois la table ci-dessus créée, vous pouvez exécuter des requêtes analytiques à l'aide d'Amazon Athena.

Déploiement de règles de qualité des données en utilisant AWS CloudFormation

Vous pouvez l'utiliser AWS CloudFormation pour créer des règles de qualité des données. Pour plus d'informations, consultez [AWS CloudFormation AWS Glue](#).

Planification de règles de qualité des données

Vous pouvez planifier des règles de qualité des données à l'aide des méthodes suivantes :

- Planifiez les règles de qualité des données à partir du catalogue de données : aucun code Les utilisateurs ne peuvent utiliser cette option pour planifier facilement leurs analyses de qualité des données. AWS Glue Data Quality créera le calendrier sur Amazon EventBridge. Pour planifier des règles de qualité des données :
 - Accédez à l'ensemble de règles et cliquez sur Exécuter.
 - Dans la section Fréquence d'exécution, sélectionnez le calendrier souhaité et indiquez un nom de tâche. Ce nom de tâche est le nom de votre calendrier dans EventBridge.
- Utilisez Amazon EventBridge et AWS Step Functions pour orchestrer les évaluations et les recommandations relatives aux règles de qualité des données.

Le chiffrement des données est arrêté pour AWS Glue Data Quality

AWS Glue Data Quality fournit un chiffrement par défaut pour protéger les données sensibles des clients au repos à l'aide de clés de chiffrement AWS détenues par nos soins.

AWS clés possédées

AWS Glue Data Quality utilise ces clés pour chiffrer automatiquement les actifs de qualité des données des clients. Vous ne pouvez pas consulter, gérer ou utiliser AWS les clés que vous possédez, ni auditer leur utilisation. Cependant, il n'est pas nécessaire de prendre des mesures ni de modifier de programme pour protéger les clés qui chiffrent vos données. Pour plus d'informations, consultez la section sur [les clés AWS détenues](#) dans le Guide du AWS KMS développeur.

Le chiffrement des données au repos par défaut permet de réduire les frais opérationnels et la complexité liés à la protection des données sensibles. Dans le même temps, il vous permet de créer des applications sécurisées qui répondent aux exigences réglementaires et de conformité strictes en matière de chiffrement.

Bien que vous ne puissiez pas désactiver cette couche de chiffrement ou sélectionner un autre type de chiffrement, vous pouvez ajouter une deuxième couche de chiffrement aux clés de chiffrement AWS détenues existantes en choisissant une clé gérée par le client lorsque vous créez vos ressources de qualité des données.

Clés gérées par le client

Clés gérées par le client : AWS Glue Data Quality prend en charge l'utilisation d'une clé symétrique gérée par le client que vous créez, détenez et gérez. Cela ajoute une deuxième couche de chiffrement par rapport au chiffrement AWS propre existant. Comme vous avez le contrôle total de cette couche de chiffrement, vous pouvez effectuer des tâches telles que :

- Établissement et gestion des stratégies de clé
- Établissement et mise à jour de politiques IAM
- Activation et désactivation des stratégies de clé
- Rotation des matériaux de chiffrement de clé
- Ajout de balises
- Création d'alias de clé
- Planification des clés pour la suppression

Pour plus d'informations, consultez la section [Clés gérées par le client](#) dans le Guide du AWS KMS développeur.

Le tableau suivant résume la manière dont AWS Glue Data Quality chiffre les différents actifs de Data Quality.

Type de données	AWS chiffrement par clé détenue	Chiffrement des clés géré par le client
Ensemble de règles relatives à la qualité des données	Activées	Activées
Chaîne d'ensemble de règles DQDL référencée par l'ensemble de règles DQ persistant. Pour le moment, ces ensembles de règles		

Type de données	AWS chiffrement par clé détenue	Chiffrement des clés géré par le client
persistants ne sont utilisés que dans l'expérience AWS Glue Data Catalog.		
Règle de qualité des données/résultats de l'analyseur Artefacts de résultat qui contiennent le statut de réussite ou d'échec de chaque règle d'un ensemble de règles ainsi que les métriques collectées par les règles et les analyseurs.	Activées	Activées
Observations Des observations sont générées lorsqu'une anomalie est détectée dans les données. Il contient des informations sur les limites supérieure et inférieure attendues et une règle suggérée basée sur ces limites. S'ils sont générés, ils sont affichés avec les résultats de qualité des données.	Activées	Activées

Type de données	AWS chiffrement par clé détenue	Chiffrement des clés géré par le client
Statistiques Contient des informations sur les métriques collectées après avoir évalué les données selon un ensemble de règles, telles que la valeur de la métrique (par exemple RowCount, Exhaustivité), les noms des colonnes et d'autres métadonnées.	Activées	Activées
Modèles statistiques de détection des anomalies Les modèles statistiques contiennent les séries chronologiques des limites supérieure et inférieure pour une métrique donnée, générées sur la base d'évaluations précédentes des données clients.	Activées	Activées

 Note

AWS Data Quality active automatiquement le chiffrement au repos à l'aide de clés AWS détenues afin de protéger gratuitement les données personnelles identifiables. Toutefois, AWS KMS des frais s'appliquent pour l'utilisation d'une clé gérée par le client. Pour plus d'informations sur la tarification, consultez [Tarification d'AWS KMS](#). Pour plus d'informations sur AWS KMS, voir [AWS KMS](#).

Création d'une clé gérée par le client

Vous pouvez créer une clé symétrique gérée par le client en utilisant le AWS Management Console, ou le AWS KMS APIs.

Pour créer une clé symétrique gérée par le client :

- Suivez les étapes de [création de AWS KMS clés de chiffrement symétriques décrites](#) dans le manuel du AWS Key Management Service développeur.

Stratégie de clé

Les stratégies de clé contrôlent l'accès à votre clé gérée par le client. Chaque clé gérée par le client doit avoir exactement une stratégie de clé, qui contient des instructions qui déterminent les personnes pouvant utiliser la clé et comment elles peuvent l'utiliser. Lorsque vous créez votre clé gérée par le client, vous pouvez spécifier une stratégie de clé. Pour plus d'informations, consultez la section [Politiques relatives aux AWS KMS clés](#) dans le Guide du AWS Key Management Service développeur.

Pour utiliser votre clé gérée par le client avec vos ressources de qualité des données, les opérations d'API suivantes doivent être autorisées dans la politique des clés :

- [kms:Decrypt](#)— Déchiffre le texte chiffré par une clé en utilisant AWS KMS
`GenerateDataKeyWithoutPlaintext`
- [kms:DescribeKey](#)— Fournit les informations clés gérées par le client pour permettre à Amazon Location de valider la clé.
- [kms:GenerateDataKeyWithoutPlaintext](#)— Renvoie une clé de données symétrique unique à utiliser en dehors de AWS KMS. Cette opération renvoie une clé de données chiffrée sous une clé KMS de chiffrement symétrique que vous spécifiez. Les octets de la clé sont aléatoires ; ils ne sont pas liés à l'appelant ou à la clé KMS. Utilisé pour réduire le nombre d'appels KMS que le client doit passer.
- [kms:ReEncrypt*](#)— Déchiffre le texte chiffré, puis le rechiffre entièrement à l'intérieur. AWS KMS Vous pouvez utiliser cette opération pour modifier la clé KMS sous laquelle les données sont chiffrées, par exemple lorsque vous [faites pivoter manuellement](#) une clé KMS ou que vous modifiez la clé KMS qui protège un texte chiffré. Vous pouvez également l'utiliser pour rechiffrer du texte chiffré sous la même clé KMS, par exemple pour modifier le [contexte de chiffrement](#) d'un texte chiffré.

Voici des exemples de déclarations de politique que vous pouvez ajouter pour Amazon Location :

```
"Statement" : [
  {
    "Sid" : "Allow access to principals authorized to use AWS Glue Data Quality",
    "Effect" : "Allow",
    "Principal" : {
      "AWS": "arn:aws:iam::<account_id>:role/ExampleRole"
    },
    "Action" : [
      "kms:Decrypt",
      "kms:DescribeKey",
      "kms:GenerateDataKeyWithoutPlaintext",
      "kms:ReEncrypt*"
    ],
    "Resource" : "*",
    "Condition" : {
      "StringEquals" : {
        "kms:ViaService" : "glue.amazonaws.com",
        "kms:CallerAccount" : "111122223333"
      }
    },
  },
  {
    "Sid": "Allow access for key administrators",
    "Effect": "Allow",
    "Principal": {
      "AWS": "arn:aws:iam::111122223333:root"
    },
    "Action" : [
      "kms:*"
    ],
    "Resource": "arn:aws:kms:region:111122223333:key/key_ID"
  },
  {
    "Sid" : "Allow read-only access to key metadata to the account",
    "Effect" : "Allow",
    "Principal" : {
      "AWS" : "arn:aws:iam::111122223333:root"
    },
    "Action" : [
      "kms:Describe*",
      "kms:Get*",
      "kms:List*",
    ],
  },
]
```

```
    "Resource" : "*"
  }
]
```

Remarques concernant l'utilisation des clés KMS dans AWS Glue Data Quality

AWS Glue Data Quality ne prend pas en charge les transitions clés. Cela signifie que si vous chiffrez vos actifs relatifs à la qualité des données avec la clé A et que vous décidez de passer à la clé B, nous ne crypterons pas à nouveau les données chiffrées avec la clé A pour utiliser la clé B. Vous pouvez toujours passer à la clé B, mais vous devrez conserver l'accès à la clé A pour accéder aux données précédemment chiffrées avec la clé A.

Pour plus d'informations sur la spécification des autorisations dans une politique, consultez la section [Autorisations pour les AWS services dans les politiques clés](#) du Guide du AWS Key Management Service développeur.

Pour plus d'informations sur la résolution des problèmes d'accès par clé, consultez la section [Résolution des problèmes d'accès par clé](#) dans le Guide du AWS Key Management Service développeur.

Création d'une configuration de sécurité

Dans AWS Glue, la [ressource Security Configurations](#) contient les propriétés nécessaires pour écrire des données chiffrées.

Pour chiffrer les actifs liés à la qualité de vos données, procédez comme suit :

1. Dans Paramètres de chiffrement, sous Paramètres avancés, choisissez Activer le chiffrement de la qualité des données
2. Sélectionnez votre clé KMS ou choisissez Créer une AWS KMS clé

[AWS Glue](#) > [Security configurations](#) > Add new security configuration

Add security configuration

Choose encryption and permission options for your accounts data catalog.

Security configuration properties

Name

Enter a unique security configuration name

Name can be up to 255 characters long. Some character set including control characters are prohibited.

Encryption settings [Info](#)

Enable and choose options for at-rest encryption.

☐ Enable S3 encryption

Enable at-rest encryption for data stored on S3.

☐ Enable CloudWatch logs encryption

Enable at-rest encryption when writing logs to Amazon CloudWatch.

▼ Advanced settings

☐ Enable job bookmark encryption

Enable at-rest encryption of job bookmark.

☒ Enable DataQuality encryption

Enable at-rest encryption of DataQuality.

AWS KMS key for DataQuality encryption

Choose an AWS KMS key or enter an ARN

Create an AWS
KMS key [↗](#)

Cancel

Create

AWS Contexte de chiffrement de Glue Data Quality

Un [contexte de chiffrement](#) est un ensemble facultatif de paires clé-valeur contenant des informations contextuelles supplémentaires sur les données.

AWS KMS utilise le contexte de chiffrement comme [données authentifiées supplémentaires](#) pour prendre en charge le chiffrement [authenticifié](#). Lorsque vous incluez un contexte de chiffrement dans une demande de chiffrement de données, AWS KMS lie le contexte de chiffrement aux données chiffrées. Pour déchiffrer les données, vous devez inclure le même contexte de chiffrement dans la demande.

AWS Exemple de contexte de chiffrement de Glue Data Quality

```
"encryptionContext": {
  "kms-arn": "arn:aws:kms:us-east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
  "branch-key-id": "111122223333+arn:aws:kms:us-east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
  "hierarchy-version": "1",
  "aws-crypto-ec:aws:glue:securityConfiguration": "111122223333:customer-security-configuration-name",
  "create-time": "2024-06-07T13:47:23:000861Z",
  "tablename": "AwsGlueMLEncryptionKeyStore",
  "type": "beacon:ACTIVE"
}
```

Utilisation du contexte de chiffrement pour la surveillance

Lorsque vous utilisez une clé symétrique gérée par le client pour chiffrer votre collection de traceurs ou de géofences, vous pouvez également utiliser le contexte de chiffrement dans les dossiers d'audit et les journaux pour identifier la manière dont la clé gérée par le client est utilisée. Le contexte de chiffrement apparaît également dans les journaux générés par AWS CloudTrail ou Amazon CloudWatch Logs.

Surveillance de vos clés de chiffrement pour AWS Glue Data Quality

Lorsque vous utilisez une clé gérée par le AWS KMS client avec vos ressources AWS Glue Data Quality, vous pouvez utiliser AWS CloudTrail ou Amazon CloudWatch Logs suivre les demandes auxquelles AWS Glue Data Quality envoie AWS KMS.

Les exemples suivants sont des AWS CloudTrail événements pour `GenerateDataKeyWithoutPlainText` et `Decrypt` pour surveiller les opérations KMS appelées par AWS Glue Data Quality afin d'accéder aux données chiffrées par votre clé gérée par le client.

Decrypt

```
{
  "eventVersion": "1.09",
  "userIdentity": {
    "type": "AssumedRole",
    "arn": "arn:aws:sts::111122223333:role/CustomerRole",
    "accountId": "111122223333",
```

```

    "invokedBy": "glue.amazonaws.com"
  },
  "eventTime": "2024-07-02T20:03:10Z",
  "eventSource": "kms.amazonaws.com",
  "eventName": "Decrypt",
  "awsRegion": "us-east-1",
  "sourceIPAddress": "glue.amazonaws.com",
  "userAgent": "glue.amazonaws.com",
  "requestParameters": {
    "keyId": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
    "encryptionAlgorithm": "SYMMETRIC_DEFAULT",
    "encryptionContext": {
      "kms-arn": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
      "branch-key-id": "111122223333+arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
      "hierarchy-version": "1",
      "aws-crypto-ec:aws:glue:securityConfiguration": "111122223333:customer-
security-configuration-name",
      "create-time": "2024-06-07T13:47:23:000861Z",
      "tablename": "AwsGlueMLEncryptionKeyStore",
      "type": "branch:ACTIVE",
      "version": "branch:version:ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE"
    }
  },
  "responseElements": null,
  "requestID": "ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE",
  "eventID": "ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE",
  "readOnly": true,
  "resources": [
    {
      "accountId": "111122223333",
      "type": "AWS::KMS::Key",
      "ARN": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE"
    }
  ],
  "eventType": "AwsApiCall",
  "managementEvent": true,
  "recipientAccountId": "111122223333",
  "eventCategory": "Management"
}

```

GenerateDataKeyWithoutPlaintext

```
{
  "eventVersion": "1.09",
  "userIdentity": {
    "type": "AssumedRole",
    "arn": "arn:aws:sts::111122223333:role/CustomerRole",
    "accountId": "111122223333",
    "invokedBy": "glue.amazonaws.com"
  },
  "eventTime": "2024-07-02T20:03:10Z",
  "eventSource": "kms.amazonaws.com",
  "eventName": "GenerateDataKeyWithoutPlaintext",
  "awsRegion": "us-east-1",
  "sourceIPAddress": "glue.amazonaws.com",
  "userAgent": "glue.amazonaws.com",
  "requestParameters": {
    "keyId": "arn:aws:kms:us-east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
    "encryptionAlgorithm": "SYMMETRIC_DEFAULT",
    "encryptionContext": {
      "kms-arn": "arn:aws:kms:us-east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
      "branch-key-id": "111122223333+arn:aws:kms:us-east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
      "hierarchy-version": "1",
      "aws-crypto-ec:aws:glue:securityConfiguration": "111122223333:customer-security-configuration-name",
      "create-time": "2024-06-07T13:47:23:000861Z",
      "tablename": "AwsGlueMLEncryptionKeyStore",
      "type": "branch:version:ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE"
    }
  },
  "responseElements": null,
  "requestID": "ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE",
  "eventID": "ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE",
  "readOnly": true,
  "resources": [
    {
      "accountId": "111122223333",
      "type": "AWS::KMS::Key",
      "ARN": "arn:aws:kms:us-east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE"
    }
  ]
}
```

```

],
"eventType": "AwsApiCall",
"managementEvent": true,
"recipientAccountId": "111122223333",
"eventCategory": "Management"
}

```

ReEncrypt

```

{
  "eventVersion": "1.09",
  "userIdentity": {
    "type": "AssumedRole",
    "arn": "arn:aws:sts::111122223333:role/CustomerRole",
    "accountId": "111122223333",
    "invokedBy": "glue.amazonaws.com"
  },
  "eventTime": "2024-07-17T21:34:41Z",
  "eventSource": "kms.amazonaws.com",
  "eventName": "ReEncrypt",
  "awsRegion": "us-east-1",
  "sourceIPAddress": "glue.amazonaws.com",
  "userAgent": "glue.amazonaws.com",
  "requestParameters": {
    "destinationEncryptionContext": {
      "kms-arn": "arn:aws:kms:us-east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
      "branch-key-id": "111122223333+arn:aws:kms:us-east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
      "hierarchy-version": "1",
      "aws-crypto-ec:aws:glue:securityConfiguration": "111122223333:customer-security-configuration-name",
      "create-time": "2024-06-07T13:47:23:000861Z",
      "tablename": "AwsGlueM1EncryptionKeyStore",
      "type": "branch:ACTIVE"
      "version": "branch:version:12345678-SAMPLE"
    },
    "destinationKeyId": "arn:aws:kms:us-east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
    "sourceAAD": "1234567890-SAMPLE+Z+lqoYOHj7VtWxJLrvh+biUFbliYDAQkobM=",
    "sourceKeyId": "arn:aws:kms:ap-southeast-2:585824196334:key/17ca05ca-a8c1-40d7-b7fd-30abb569a53a",
    "destinationEncryptionAlgorithm": "SYMMETRIC_DEFAULT",

```



```

    "sourceEncryptionContext": {
      "kms-arn": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
      "branch-key-id": "111122223333+arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
      "hierarchy-version": "1",
      "aws-crypto-ec:aws:glue:securityConfiguration": "111122223333:customer-
security-configuration-name",
      "create-time": "2024-06-07T13:47:23:000861Z",
      "tablename": "AwsGlueMLEncryptionKeyStore",
      "type": "branch:version:ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE"
    },
    "destinationAAD": "1234567890-SAMPLE",
    "sourceEncryptionAlgorithm": "SYMMETRIC_DEFAULT"
  },
  "responseElements": null,
  "requestID": "ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE",
  "eventID": "ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE",
  "readOnly": true,
  "resources": [
    {
      "accountId": "111122223333",
      "type": "AWS::KMS::Key",
      "ARN": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE"
    },
    {
      "accountId": "111122223333",
      "type": "AWS::KMS::Key",
      "ARN": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE"
    }
  ],
  "eventType": "AwsApiCall",
  "managementEvent": true,
  "recipientAccountId": "111122223333",
  "eventCategory": "Management"
}

```

En savoir plus

Les ressources suivantes fournissent plus d'informations sur le chiffrement des données au repos.

- Pour plus d'informations sur les [concepts AWS Key Management Service de base](#), consultez le guide du AWS Key Management Service développeur.
- Pour plus d'informations sur les [meilleures pratiques en matière de sécurité](#), AWS Key Management Service consultez le guide du AWS Key Management Service développeur.

Résolution des erreurs liées à la qualité des données de AWS Glue

Si vous rencontrez des erreurs dans AWS Glue Data Quality, utilisez les solutions suivantes pour trouver la source des problèmes et les résoudre.

Table des matières

- [Erreur : module AWS Glue Data Quality manquant](#)
- [Erreur : autorisations insuffisantes pour AWS Lake Formation](#)
- [Erreur : les ensembles de règles ne sont pas nommés de manière unique](#)
- [Erreur : tables contenant des caractères spéciaux](#)
- [Erreur : erreur de débordement avec un ensemble de règles volumineux](#)
- [Erreur : échec du statut général de la règle](#)
- [AnalysisException: Impossible de vérifier l'existence de la base de données par défaut](#)
- [Message d'erreur : la clé de distribution fournie ne convient pas aux cadres de données fournies.](#)
- [Exception dans la classe utilisateur : java.lang. RuntimeException : Impossible de récupérer les données. Vérifiez les connexions CloudWatch pour obtenir plus de détails](#)
- [ERREUR DE LANCEMENT : erreur lors du téléchargement depuis S3 pour le compartiment](#)
- [InvalidInputException \(statut : 400\) : DataQuality les règles ne peuvent pas être analysées](#)
- [Erreur : Eventbridge ne déclenche pas les tâches Glue DQ selon le calendrier que j'ai configuré.](#)
- [Erreurs CustomSQL](#)
- [Règles dynamiques](#)
- [Exception dans la classe utilisateur : org.apache.spark.sql. AnalysisException: org.apache.hadoop.hive.ql.metadata. HiveException](#)
- [UNCLASSIFIED_ERROR ; IllegalArgumentException : Erreur d'analyse : aucune règle ni analyseur fournis., aucune alternative viable en entrée](#)

Erreur : module AWS Glue Data Quality manquant

Message d'erreur : aucun module nommé « awsgluedq ».

Résolution : Cette erreur se produit lorsque vous exécutez AWS Glue Data Quality dans une version non prise en charge. AWS Glue Data Quality n'est prise en charge que dans les versions 3.0 et ultérieures de Glue.

Erreur : autorisations insuffisantes pour AWS Lake Formation

Message d'erreur : Exception dans la classe utilisateur :

`com.amazonaws.services.glue.model.AccessDeniedException` : Autorisations de Lake Formation insuffisantes sur `impact_sdg_involvement` (Service : AWS Glue; Code d'état : 400 ; Code d'erreur : ; ID de demande : 465ae693-b7ba-4df0-a4e4-6b17xxxxxxx AccessDeniedException ; Proxy : nul).

Résolution : Vous devez fournir des autorisations suffisantes dans AWS Lake Formation.

Erreur : les ensembles de règles ne sont pas nommés de manière unique

Message d'erreur : Exception dans la classe utilisateur :... `services.glue.model`.

`AlreadyExistsException`: Un autre ensemble de règles portant le même nom existe déjà.

Résolution : les ensembles de règles sont globaux et doivent être uniques.

Erreur : tables contenant des caractères spéciaux

Message d'erreur : Exception dans la classe utilisateur : `org.apache.spark.sql. AnalysisException`: impossible de résoudre les colonnes d'entrée « C » données : [`primary.data_end_time`, `primary.data_start_time`, `primary.end_time`, `primary.last_updated`, `primary.message`, `primary.process_date`, `primary.rowhash`, `primary.run_by`, `primary.run_id`, `primary.start_time`, `primary.status`] ; ligne 1 pos 44 ;.

Résolution : Il existe actuellement une limite selon laquelle AWS Glue Data Quality ne peut pas être exécuté sur des tables contenant des caractères spéciaux tels que «. ».

Erreur : erreur de débordement avec un ensemble de règles volumineux

Message d'erreur : Exception dans la classe utilisateur : `java.lang. StackOverflowError`.

Résolution : si vous disposez d'un ensemble de règles de plus de 2 000 règles, vous pouvez rencontrer ce problème. Divisez vos règles en plusieurs ensembles de règles.

Erreur : échec du statut général de la règle

Condition d'erreur : mon ensemble de règles est réussi, mais le statut général de mes règles est un échec.

Résolution : Cette erreur s'est probablement produite parce que vous avez choisi l'option de publier les statistiques sur Amazon CloudWatch lors de la publication. Si votre ensemble de données se trouve dans un VPC, celui-ci n'autorise peut-être pas AWS Glue à publier des métriques sur Amazon. CloudWatch Dans ce cas, vous devez configurer un point de terminaison pour que votre VPC puisse accéder à Amazon. CloudWatch

AnalysisException: Impossible de vérifier l'existence de la base de données par défaut

Condition d'erreur AnalysisException : Impossible de vérifier l'existence de la base de données par défaut : com.amazonaws.services.glue.model. AccessDeniedException: Autorisations de formation lacustre insuffisantes par défaut (Service : AWS Glue; Code d'état : 400 ; Code d'erreur : AccessDeniedException ; ID de demande : XXXXXXXXX-XXXX-XXXX-XXXX -XXXXXXXXXXXX ; Proxy : nul)

Résolution : En AWS Glue intégration du catalogue des offres d'emploi, AWS Glue essaie toujours de vérifier si la base de données par défaut existe ou non en utilisant AWS Glue GetDatabase API. Lorsque l'autorisation DESCRIBE Lake Formation n'est pas accordée ou que GetDatabase IAM l'autorisation est accordée, la tâche échoue lors de la vérification de l'existence de la base de données par défaut.

Pour résoudre le problème :

1. Ajoutez l'autorisation DESCRIBE dans Lake Formation pour la base de données par défaut.
2. Configurez le rôle IAM attaché au AWS Glue poste de créateur de base de données dans Lake Formation. Cela crée automatiquement une base de données par défaut et accorde les autorisations Lake Formation requises pour le rôle.
3. Désactivez l'option `--enable-data-catalog`. (Il est affiché sous la forme Utilisation Data Catalog comme le métastore Hive dans AWS Glue Studio).

Si vous n'avez pas besoin de Spark SQL Data Catalog intégration dans le job, vous pouvez la désactiver.

Message d'erreur : la clé de distribution fournie ne convient pas aux cadres de données fournies.

Condition d'erreur : la clé de distribution fournie ne convient pas aux cadres de données fournies.

Résolution : vous utilisez le DataSetMatchtype de règle et les clés de jointure sont dupliquées. Vos clés de jointure doivent être uniques et ne doivent pas être nulles. Dans les cas où vous ne pouvez pas avoir de clés de jointure uniques, envisagez d'utiliser d'autres types de règles, par exemple AggregateMatch pour établir une correspondance sur des données récapitulatives.

Exception dans la classe utilisateur : java.lang. RuntimeException : Impossible de récupérer les données. Vérifiez les connexions CloudWatch pour obtenir plus de détails

Condition d'erreur : exception dans la classe utilisateur : java.lang. RuntimeException : Impossible de récupérer les données. Vérifiez les connexions CloudWatch pour obtenir plus de détails.

Résolution : Cela se produit lorsque vous créez des règles DQ sur un tableau basé sur Amazon S3 qui est comparé à Amazon RDS ou Amazon Redshift. Dans ces cas, AWS Glue Impossible de charger la connexion. Essayez plutôt de configurer une règle DQ sur le jeu de données Amazon Redshift ou Amazon RDS. Il s'agit d'un bogue connu.

ERREUR DE LANCEMENT : erreur lors du téléchargement depuis S3 pour le compartiment

Condition d'erreur : ERREUR DE LANCEMENT : erreur lors du téléchargement depuis S3 pour le compartiment : aws-glue-ml-data-quality-assets-us-east-1, key: jars/aws-glue-ml-data-quality-etl.jar. Access Denied (Service: Amazon S3; Status Code: 403; Please refer logs for details) .

Résolution : Les autorisations associées au rôle transmises à AWS Glue Data Quality doivent permettre la lecture depuis l'emplacement Amazon S3 précédent. Cette politique IAM doit être associée au rôle :

```
{
  "Sid": "allowS3",
  "Effect": "Allow",
  "Action": "s3:GetObject",
  "Resource": "arn:aws:s3::aws-glue-ml-data-quality-assets-<region>/*"
}
```

Reportez-vous à [Data Quality authorization](#) pour obtenir la liste des autorisations détaillées. Ces bibliothèques sont nécessaires pour évaluer la qualité des données de vos jeux de données.

InvalidInputException (statut : 400) : DataQuality les règles ne peuvent pas être analysées

Condition d'erreur : InvalidInputException (statut : 400) : DataQuality les règles ne peuvent pas être analysées.

Résolution : il existe de nombreuses possibilités pour cette erreur. Il est possible que vos règles comportent des guillemets simples. Assurez-vous qu'ils sont entre guillemets. Par exemple :

```
Rules = [
  ColumnValues "tipo_vinculo" in ["COD0", "DOC0", "COC0", "DOD0"] AND "categoria" = 'ES'
    AND "cod_bandera" = 'CEP'
```

Remplacer par :

```
Rules = [
  (ColumnValues "tipovinculo" in [ "COD0", "DOC0", "COC0", "DOD0"]) AND (ColumnValues
    "categoria" = "ES")
    AND (ColumnValues "codbandera" = "CEP")
]
```

Erreur : Eventbridge ne déclenche pas les tâches Glue DQ selon le calendrier que j'ai configuré.

Condition d'erreur : Eventbridge ne se déclenche pas AWS Glue Data Quality tâches basées sur le calendrier que j'ai configuré.

Résolution : le rôle déclenchant la tâche ne dispose peut-être pas des autorisations appropriées. Assurez-vous que le rôle que vous utilisez pour lancer les tâches dispose des autorisations mentionnées dans la rubrique [Configuration IAM nécessaire à la planification des évaluations](#).

Erreurs CustomSQL

Condition d'erreur : The output from CustomSQL must contain at least one column that matches the input dataset for AWS Glue Data Quality to provide row level results. The SQL query is a valid query but no columns from the SQL result are present in the Input Dataset. Ensure that matching columns are returned from the SQL.

Résolution : la requête SQL est valide, mais assurez-vous que vous ne sélectionnez que les colonnes de la table principale. La sélection de fonctions d'agrégation telles que somme, nombre sur les colonnes à partir de la table principale peut entraîner cette erreur.

Condition d'erreur : There was a problem when executing your SQL statement: cannot resolve "Col".

Résolution : cette colonne n'est pas présente dans la table principale.

Condition d'erreur : The columns that are returned from the SQL statement should only belong to the primary table. "In this case, some columns (Col) belong to reference table".

Résolution : dans les requêtes SQL, lorsque vous attachez la table principale à d'autres tables de référence, assurez-vous que votre instruction SELECT ne contient que des noms de colonnes de votre table principale afin de générer des résultats au niveau de la ligne pour la table principale.

Règles dynamiques

Condition d'erreur: Dynamic rules require job context, and cannot be evaluated in interactive session or data preview..

Cause : ce message d'erreur peut apparaître dans les résultats de l'aperçu des données, ou dans d'autres sessions interactives, lorsque votre jeu de règles contient des règles DQ dynamiques. Les règles dynamiques font référence à des métriques historiques associées à un nom de tâche et à un

contexte d'évaluation particuliers, de sorte qu'elles ne peuvent pas être évaluées lors de sessions interactives.

Résolution : Exécuter votre AWS Glue La tâche produira des métriques historiques, qui pourront être référencées lors d'exécutions ultérieures pour la même tâche.

Condition d'erreur :

- `[RuleType] rule only supports simple atomic operands in thresholds..`
- `Function last not yet implemented for [RuleType] rule.`

Résolution : les règles dynamiques sont généralement prises en charge pour tous les types de règles DQDL dans les expressions numériques (voir [Référence DQDL](#)). Cependant, certaines règles qui produisent plusieurs métriques ne sont pas encore prises en charge. `ColumnValues` `ColumnLength`

Condition d'erreur : `Binary expression operands must resolve to a single number..`

Cause : les règles dynamiques prennent en charge les expressions binaires, telles que `RowCount > avg(last(5)) * 0.9`. Ici, l'expression binaire est `avg(last(5)) * 0.9`. Cette règle est valide parce que les opérandes `avg(last(5))` et `0.9` se résolvent en un seul nombre. Un exemple incorrect est `RowCount > last(5) * 0.9` parce que `last(5)` produira une liste qui ne pourra pas être comparée de manière significative au nombre actuel de lignes.

Résolution : utilisez des fonctions d'agrégation pour réduire un opérande à valeurs multiples en un seul nombre.

Condition d'erreur :

- `Rule threshold results in list, and a single value is expected.`
Use aggregation functions to produce a single value. Valid example: `sum(last(10)), avg(last(10))`.
- `Rule threshold results in empty list, and a single value is expected.`

Cause : les règles dynamiques peuvent être utilisées pour comparer certaines fonctionnalités de votre jeu de données avec ses valeurs historiques. La fonction « last » permet de récupérer plusieurs valeurs historiques, à condition de fournir un argument entier positif. Par exemple, `last(5)` récupérera les cinq dernières valeurs observées lors des exécutions de tâches pour votre règle.

Résolution : une fonction d'agrégation doit être utilisée pour réduire ces valeurs en un seul nombre afin de réaliser une comparaison significative avec la valeur observée dans l'exécution de tâche actuelle.

Exemples valides :

- `RowCount >= avg(last(5))`
- `RowCount > last(1)`
- `RowCount < last()`

Exemple non valide : `RowCount > last(5)`.

Condition d'erreur :

- Function index used in threshold requires positive integer argument.
- Index argument must be an integer. Valid syntax example: `RowCount > index(last(10, 2))`, which means RowCount must be greater than third most recent execution from last 10 job runs.

Résolution : lors de la création de règles dynamiques, vous pouvez utiliser la fonction d'agrégation `index` pour sélectionner une valeur historique à partir d'une liste. Par exemple, `RowCount > index(last(5), 1)` vérifiera si le nombre de lignes observé dans l'exécution de tâche actuelle est strictement supérieur au nombre de lignes le plus récent, après le dernier, observé pour votre tâche. `index` est indexé à partir de zéro.

Condition d'erreur : `IllegalArgumentException: Parsing Error: Rule Type: DetectAnomalies is not valid.`

Résolution : La détection des anomalies n'est disponible que dans AWS Glue 4.0.

Condition d'erreur : `IllegalArgumentException: Parsing Error: Unexpected condition for rule of type ... no viable alternative at input ....`

Remarque : ... est dynamique. Exemple: `IllegalArgumentException: Parsing Error: Unexpected condition for rule of type RowCount with number return type, line 4:19 no viable alternative at input '>last'.`

Résolution : La détection des anomalies n'est disponible que dans AWS Glue 4.0.

Exception dans la classe utilisateur : org.apache.spark.sql.

AnalysisException: org.apache.hadoop.hive ql.metadata. HiveException

Condition d'erreur : Exception in User Class:

org.apache.spark.sql.AnalysisException:

org.apache.hadoop.hive ql.metadata.HiveException: Unable to fetch table mailpiece_submitted. StorageDescriptor#InputFormat cannot be null for table: mailpiece_submitted (Service: null; Status Code: 0; Error Code: null; Request ID: null; Proxy: null)

Cause : vous utilisez Apache Iceberg dans AWS Glue Data Catalog et l'attribut Input Format est vide dans AWS Glue Data Catalog.

Résolution : Ce problème se produit lorsque vous utilisez le type de règle CustomSQL dans votre règle DQ. Une façon de résoudre ce problème consiste à utiliser « principal » ou à ajouter un nom de catalogue glue_catalog. à <database>.<table> in Custom rule type.

UNCLASSIFIED_ERROR ; IllegalArgumentException : Erreur d'analyse : aucune règle ni analyseur fournis., aucune alternative viable en entrée

Condition d'erreur : UNCLASSIFIED_ERROR; IllegalArgumentException: Parsing Error: No rules or analyzers provided., no viable alternative at input

Résolution : Le DQDL n'est pas analysable. Cela peut se produire dans quelques cas. Si vous utilisez des règles composites, assurez-vous qu'elles comportent des parenthèses droites.

```
(RowCount >= avg(last(10)) * 0.6) and (RowCount <= avg(last(10)) * 1.4) instead of  
RowCount >= avg(last(10)) * 0.6 and RowCount <= avg(last(10)) * 1.4
```

Intégration des données Amazon Q dans AWS Glue

L'intégration de données dans Amazon Q AWS Glue est une nouvelle fonctionnalité d'IA générative AWS Glue qui permet aux ingénieurs de données et aux développeurs ETL de créer des tâches d'intégration de données en langage naturel. Les ingénieurs et les développeurs peuvent demander à Amazon Q de créer des tâches, de résoudre des problèmes et de répondre à des questions concernant AWS Glue l'intégration des données.

Qu'est-ce qu'Amazon Q ?

Note

Propulsé par Amazon Bedrock : AWS implémente la [détection automatique des abus](#). L'intégration des données Amazon Q étant basée sur Amazon Bedrock, les utilisateurs peuvent tirer pleinement parti des contrôles mis en œuvre dans Amazon Bedrock pour renforcer la sûreté, la sécurité et l'utilisation responsable de l'intelligence artificielle (IA).

Amazon Q est un assistant conversationnel basé sur l'intelligence artificielle générative (IA) qui peut vous aider à comprendre, créer, étendre et exploiter AWS des applications. Le modèle sur lequel repose Amazon Q a été enrichi d'un AWS contenu de haute qualité afin de vous fournir des réponses plus complètes, exploitables et référencées afin d'accélérer votre développement. AWS Pour plus d'informations, consultez la rubrique [Qu'est-ce qu'Amazon Q ?](#)

Qu'est-ce que l'intégration des données Amazon Q dans AWS Glue ?

L'intégration des données Amazon Q AWS Glue inclut les fonctionnalités suivantes :

- Chat : Amazon Q Data Integration in AWS Glue peut répondre à des questions en langage naturel en anglais sur AWS Glue des domaines tels que les connecteurs AWS Glue source et de destination, les tâches AWS Glue ETL, le catalogue de données, les robots d'exploration et AWS Lake Formation d'autres documents relatifs aux fonctionnalités, ainsi que les meilleures pratiques. L'intégration des données Amazon Q AWS Glue répond par des step-by-step instructions et inclut des références à ses sources d'informations.

- Génération de code d'intégration de données — L'intégration de données Amazon Q AWS Glue permet de répondre à des questions sur les scripts AWS Glue ETL et de générer du nouveau code à partir d'une question en langage naturel en anglais.
- Résolution des problèmes : l'intégration des données dans Amazon Q AWS Glue est spécialement conçue pour vous aider à comprendre les erreurs dans les AWS Glue tâches et fournit des step-by-step instructions pour déterminer la cause de vos problèmes et les résoudre.


Note

L'intégration des données Amazon Q dans Amazon Q AWS Glue n'utilise pas le contexte de votre conversation pour éclairer les réponses futures pendant toute la durée de votre conversation. Chaque conversation avec l'intégration de données Amazon Q AWS Glue est indépendante de vos conversations précédentes ou futures.

Vous utilisez l'intégration des données Amazon Q dans AWS Glue ?

Dans le panneau Amazon Q, vous pouvez demander à Amazon Q de générer du code pour un script AWS Glue ETL, ou de répondre à une question sur les AWS Glue fonctionnalités ou de résoudre une erreur. La réponse est un script ETL contenant PySpark des step-by-step instructions pour personnaliser le script, le réviser et l'exécuter. Pour les questions, la réponse est générée à partir de la base de connaissances sur l'intégration des données, avec un résumé et l'URL de la source pour les références.

Par exemple, vous pouvez demander à Amazon Q de « Veuillez fournir un script Glue qui lit depuis Snowflake, renomme les champs et écrit sur Redshift » et en réponse, l'intégration des données Amazon Q AWS Glue renverra un script de AWS Glue tâche capable d'effectuer l'action demandée. Vous pouvez vérifier le code généré pour vous assurer qu'il répond à l'intention demandée. Si vous êtes satisfait, vous pouvez le déployer en tant que AWS Glue tâche en production. Vous pouvez résoudre les problèmes liés aux tâches en demandant à l'intégration d'expliquer les erreurs et les échecs et de proposer des solutions. Amazon Q peut répondre aux questions concernant les AWS Glue meilleures pratiques en matière d'intégration des données.



Voici des exemples de questions qui montrent comment l'intégration des données Amazon Q dans Amazon Q AWS Glue peut vous aider à tirer parti de ce qui suit AWS Glue :

AWS Glue Génération de code ETL :

- Écrivez un AWS Glue script qui lit le JSON depuis S3, transforme les champs à l'aide du mappage d'application et écrit sur Amazon Redshift
- Comment écrire un AWS Glue script pour lire depuis DynamoDB, appliquer la transformation et écrire DropNullFields dans S3 en tant que Parquet ?
- Donnez-moi un AWS Glue script qui lit depuis MySQL, supprime certains champs en fonction de ma logique métier et écrit dans Snowflake
- Rédigez une AWS Glue tâche à lire depuis DynamoDB et à écrire dans S3 au format JSON
- Aidez-moi à développer un AWS Glue script pour AWS Glue Data Catalog to S3
- Rédigez une AWS Glue tâche pour lire le JSON depuis S3, supprimer les valeurs nulles et écrire dans Redshift

AWS Glue explications sur les fonctionnalités :

- Comment utiliser la qualité AWS Glue des données ?
- Comment utiliser les signets AWS Glue d'offres d'emploi ?

- Comment activer la mise à l' AWS Glue échelle automatique ?
- Quelle est la différence entre les cadres AWS Glue dynamiques et les blocs de données Spark ?
- Quels sont les différents types de connexions pris en charge AWS Glue ?

AWS Glue résolution des problèmes :

- Comment résoudre les erreurs de mémoire insuffisante (OOM) sur les tâches ? AWS Glue
- Quels sont les messages d'erreur susceptibles de s'afficher lors de la configuration de la qualité AWS Glue des données et comment pouvez-vous les corriger ?
- Comment corriger une AWS Glue tâche avec le message d'erreur « Accès refusé à Amazon S3 » ?
- Comment résoudre les problèmes liés au transfert des données sur AWS Glue les tâches ?

Bonnes pratiques pour interagir avec l'intégration des données Amazon Q

Voici les meilleures pratiques pour interagir avec l'intégration des données Amazon Q :

- Lorsque vous interagissez avec l'intégration de données Amazon Q, posez des questions spécifiques, répétez lorsque vous avez des demandes complexes et vérifiez l'exactitude des réponses.
- Lorsque vous fournissez des instructions d'intégration de données en langage naturel, soyez aussi précis que possible pour aider l'assistant à comprendre exactement ce dont vous avez besoin. Au lieu de demander « extraire les données de S3 », fournissez plus de détails, tels que « écrivez un AWS Glue script qui extrait les fichiers JSON de S3 ».
- Vérifiez le script généré avant de l'exécuter pour garantir son exactitude. Si le script généré comporte des erreurs ou ne correspond pas à votre intention, fournissez des instructions à l'assistant pour savoir comment le corriger.
- La technologie d'IA générative est nouvelle et les réponses peuvent comporter des erreurs, parfois appelées hallucinations. Testez et passez en revue tout le code pour détecter des erreurs et des vulnérabilités avant de l'utiliser dans votre environnement ou votre charge de travail.

Intégration des données Amazon Q dans l'amélioration des AWS Glue services

Pour faciliter l'intégration des données Amazon Q et AWS Glue fournir les informations les plus pertinentes sur les AWS services, nous pouvons utiliser certains contenus d'Amazon Q, tels que les questions que vous posez à Amazon Q et ses réponses, afin d'améliorer le service.

Pour plus d'informations sur le contenu que nous utilisons et sur la manière de nous désinscrire, consultez l'[amélioration du service Amazon Q Developer](#) dans le guide de l'utilisateur Amazon Q Developer.

Considérations

Prenez en compte les éléments suivants avant d'utiliser l'intégration de données Amazon Q dans AWS Glue :

- Actuellement, la génération de code ne fonctionne qu'avec PySpark le noyau. Le code généré est destiné aux AWS Glue tâches basées sur Python Spark.
- Pour plus d'informations sur les combinaisons de fonctionnalités de génération de code prises en charge pour l'intégration de données Amazon Q dans AWS Glue, consultez [Fonctionnalités de génération de code prises en charge](#).

Configuration de l'intégration des données Amazon Q dans AWS Glue

Les sections suivantes présentent des informations sur la configuration de l'intégration des données Amazon Q dans AWS Glue.

Rubriques

- [Configuration des autorisations IAM](#)

Configuration des autorisations IAM

Cette rubrique décrit les autorisations IAM que vous configurez pour l'expérience de chat Amazon Q et l'expérience du bloc-notes AWS Glue Studio.

Rubriques

- [Configuration des autorisations IAM pour le chat Amazon Q](#)
- [Configuration des autorisations IAM pour les blocs-notes AWS Glue Studio](#)

Configuration des autorisations IAM pour le chat Amazon Q

L'octroi d'autorisations à l'intégration des données APIs Used by Amazon Q AWS Glue nécessite des autorisations AWS Identity and Access Management (IAM) appropriées. Vous pouvez obtenir des autorisations en associant la AWS politique personnalisée suivante à votre identité IAM (comme un utilisateur, un rôle ou un groupe) :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:StartCompletion",
        "glue:GetCompletion"
      ],
      "Resource": [
        "arn:aws:glue:*:*:completion/*"
      ]
    }
  ]
}
```

Configuration des autorisations IAM pour les blocs-notes AWS Glue Studio

Pour activer l'intégration des données Amazon Q dans les blocs-notes AWS Glue Studio, assurez-vous que l'autorisation suivante est attachée au rôle IAM du bloc-notes :

Note

Le `codewhisperer` préfixe est un ancien nom issu d'un service fusionné avec Amazon Q Developer. Pour plus d'informations, consultez [Amazon Q Developer Rename - Résumé des modifications](#).


```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:StartCompletion",
        "glue:GetCompletion"
      ],
      "Resource": [
        "arn:aws:glue:*:*:completion/*"
      ]
    },
    {
      "Sid": "AmazonQDeveloperPermissions",
      "Effect": "Allow",
      "Action": [
        "codewhisperer:GenerateRecommendations"
      ],
      "Resource": "*"
    }
  ]
}
```

Note

L'intégration des données dans Amazon Q AWS Glue n'est pas disponible via le AWS SDK que vous pouvez utiliser par programmation. APIs Les deux éléments suivants sont utilisés dans la politique IAM pour permettre cette expérience via le panneau de discussion Amazon Q ou les blocs-notes AWS Glue Studio : StartCompletion et GetCompletion

Attribution d'autorisations

Pour activer l'accès, ajoutez des autorisations à vos utilisateurs, groupes ou rôles :

- Utilisateurs et groupes dans AWS IAM Identity Center : créez un ensemble d'autorisations. Suivez les instructions de la section [Création d'un ensemble d'autorisations](#) dans le guide de l'utilisateur d'AWS IAM Identity Center.

- Utilisateurs gérés dans IAM via un fournisseur d'identité : créez un rôle pour la fédération d'identités. Pour plus d'informations, voir la rubrique [Création d'un rôle pour un fournisseur d'identité tiers \(fédération\)](#) du Guide de l'utilisateur IAM.
- Utilisateurs IAM :
 - Créez un rôle que votre utilisateur peut assumer. Suivez les instructions de la rubrique [Création d'un rôle pour un utilisateur IAM](#) du Guide de l'utilisateur IAM.
 - (Non recommandé) Attachez une politique directement à un utilisateur ou ajoutez un utilisateur à un groupe d'utilisateurs. Suivez les instructions de la rubrique [Ajout d'autorisations à un utilisateur \(console\)](#) du Guide de l'utilisateur IAM.

Fonctionnalités de génération de code prises en charge

Vous trouverez ci-dessous les combinaisons des fonctionnalités de génération de code associées à l'intégration de données Amazon Q.

Sources et cibles	Transformation
S3 avec les types de format suivants : json, csv, parquet, hudi, delta	Drop
AWS Glue Data Catalog	Regrouper
Lac rouge	DropDuplicates
Amazon DynamoDB	Joindre
MySQL	Filtre
Oracle	RenameColumns
PostgreSQL	FillNull
Microsoft SQL Server	DropNull
Amazon DocumentDB//MongoDB	WithColumns
Snowflake	Requête SQL

Sources et cibles	Transformation
Google BigQuery	Union
Teradata	Select
Amazon OpenSearch Service	
Vertica	
SAP HANA	
Amazon Redshift	

Exemples d'interactions

L'intégration des données Amazon Q vous AWS Glue permet de saisir votre question dans le panneau Amazon Q. Vous pouvez saisir une question concernant la fonctionnalité d'intégration des données fournie par AWS Glue. Une réponse détaillée, accompagnée des documents de référence, vous sera renvoyée.

Un autre cas d'utilisation est la génération de scripts de travail AWS Glue ETL. Vous pouvez poser une question concernant la manière d'effectuer une tâche d'extraction, de transformation ou de chargement de données. Un PySpark script généré sera renvoyé.

Rubriques

- [Interactions par chat avec Amazon Q](#)
- [AWS Glue Interactions avec Studio Notebook](#)

Interactions par chat avec Amazon Q

Sur la AWS Glue console, commencez à créer une nouvelle tâche et demandez à Amazon Q :
 « Créez un flux Glue ETL, connectez-vous à deux tables du catalogue Glue, lieu et événement, dans ma base de données glue_db, joignez les résultats sur le lieu et le e_venueid de l'événement, puis filtrez sur l'état du lieu avec la condition VenueState=='DC' et écrivez sur s3://amzn-s3-demo -/au format CSV. » bucket/codegen/BDB-9999/output

The screenshot displays the AWS Glue Query Editor interface. On the left, the 'Data' sidebar shows the 'glue_db' database and a table named 'venue'. The main editor area contains the SQL query: `SELECT * FROM 'glue_db'.venue' limit 10;`. Below the query, the 'Query results' section shows a 'Completed' status with a green bar. The results table has 10 rows and 6 columns: #, venueid, venue name, venue city, venue state, and venue seats. The data includes Toyota Park, Columbus Crew Stadium, RFK Stadium, CommunityAmerica Ballpark, Gillette Stadium, New York Giants Stadium, and BMO Field.

#	venueid	venue name	venue city	venue state	venue seats
1	1	Toyota Park	Bridgeview	IL	0
2	2	Columbus Crew Stadium	Columbus	OH	0
3	3	RFK Stadium	Washington	DC	0
4	4	CommunityAmerica Ballpark	Kansas City	KS	0
5	5	Gillette Stadium	Foxborough	MA	68756
6	6	New York Giants Stadium	East Rutherford	NJ	80242
7	7	BMO Field	Toronto	ON	0

Vous remarquerez que le code est généré. Grâce à cette réponse, vous pouvez apprendre et comprendre comment créer AWS Glue du code adapté à vos besoins. Vous pouvez copier/coller le code généré dans l'éditeur de script et configurer des espaces réservés. Après avoir configuré un rôle IAM et AWS Glue les connexions sur la tâche, enregistrez et exécutez la tâche. Une fois le travail terminé, vous pouvez vérifier que les données récapitulatives sont conservées dans Amazon S3 comme prévu et qu'elles peuvent être utilisées par vos charges de travail en aval.

AWS Glue Interactions avec Studio Notebook

Note

L'expérience d'intégration des données Amazon Q dans le AWS Glue Studio bloc-notes se concentre toujours sur le flux d'intégration de données DynamicFrame basé sur le flux.

Ajoutez une nouvelle cellule et entrez votre commentaire pour décrire ce que vous souhaitez réaliser. Après avoir appuyé sur Tab et sur Entrée, le code recommandé s'affiche.

Le premier objectif est d'extraire les données : « Donnez-moi du code qui lit une table du catalogue de données Glue », puis « Donnez-moi du code pour appliquer une transformation de filtre avec `star_rating>3` » et « Donnez-moi du code qui écrit le cadre dans S3 sous forme de parquet ».

q-nodes

Stop notebookDownload NotebookActionsSaveRun

NotebookScriptJob detailsRunsData quality - updatedSchedulesVersion Control

+⏮️📄📋▶️■↺▶️▶️Code ▾Glue PySpark 🔌

```
Worker Type: G.1X  
Number of Workers: 5  
Session ID: a6846a9a-6489-4599-bf8d-066b59d887da  
Applying the following default arguments:  
--glue_kernel_version 1.0.4  
--enable-glue-datacatalog true  
Waiting for session a6846a9a-6489-4599-bf8d-066b59d887da to get into ready status...  
Session a6846a9a-6489-4599-bf8d-066b59d887da has been created.
```

[]:

📄↑↓🖨️🔍🗑️

0 1 🌐 ⚙️ Initialized (additional servers needed) Glue PySpark | Idle ✓ CodeWhispererMode: EditLn 1, Col 1Untitled.ipynb0

cloudShellFeedback© 2024, Amazon Web Services, Inc. or its affiliates.PrivacyTermsCookie preferences

q-nodes

Stop notebook

Download Notebook

Actions

Save

Run

Notebook

Script

Job details

Runs

Data quality - updated

Schedules

Version Control

+

✂

📄

📄

▶

■

↺

▶▶

Code

Glue PySpark

```

2022-01-27 00:00:00| 2022-01-27 00:00:00| 2022-01-27 00:00:00| 2022-01-27 00:00:00| 2022-01-27 00:00:00|
Marine end-to-e...|Lake maracaibo in...| 2013| 25| US|2013-01-27 00:00:00| 207443|white gold anklet...| Jewelry| 5|Re
| 23008|RDYS06F9USEZLSG| N| 6|
gular supply al...|Amongst other neg...| 2013| 5| US|2013-01-11 00:00:00| 352961|silver-plated hai...| Jewelry| 5|Gr
| 89950|RBJPZWSA0NG285W| N| 2|
oundwater recha...|Not exactly were ...| 2013|

```

only showing top 20 rows

[]:

📄

↑

↓

🔍

🗑

0

1

Initialized (additional servers needed)

Glue PySpark | Idle

✓ CodeWhisperer

Mode: Command

Ln 1, Col 1

Untitled.ipynb

0

🔔


Comme pour l'expérience de chat Amazon Q, le code est recommandé. Si vous appuyez sur Tab, le code recommandé est sélectionné.

Vous pouvez exécuter chaque cellule en renseignant les options appropriées pour vos sources dans le code généré. À tout moment des exécutions, vous pouvez également prévisualiser un échantillon de votre ensemble de données à l'aide de la `show()` méthode.

Vous pouvez exécuter le bloc-notes en tant que tâche, soit par programmation, soit en choisissant Exécuter.

Invites complexes

Vous pouvez générer un script complet à l'aide d'une seule invite complexe. « J'ai des données JSON dans S3 et des données dans Oracle qui doivent être combinées. Veuillez fournir un script Glue qui lit les deux sources, effectue une jointure, puis écrit les résultats dans Redshift. »



Vous remarquerez peut-être que, dans le bloc-notes, l'intégration des données Amazon Q a AWS Glue généré le même extrait de code que celui généré dans le chat Amazon Q.

Vous pouvez exécuter le bloc-notes en tant que tâche, soit en choisissant Exécuter, soit par programmation.

Utiliser la connaissance du contexte avec Amazon Q Data Integration in AWS Glue

Vous pouvez désormais créer des tâches de traitement de données de manière plus efficace grâce à la prise en compte du contexte basée sur les requêtes et à la génération de PySpark DataFrame code dans Amazon Q Data Integration. Par exemple, vous pouvez utiliser cette invite pour générer PySpark du code : « créez une tâche pour charger les données de vente à partir de la table Redshift 'analytics.salesorder' en utilisant la connexion 'erp_conn', filtrez order_amount en dessous de 50 dollars et enregistrez sur Amazon S3 au format parquet ».

Amazon Q générera le script en fonction de votre demande et configurera le flux de travail d'intégration des données avec les détails fournis dans votre question, tels que les configurations de connexion, les détails du schéma, les noms des bases de données/tables et les spécifications des colonnes pour les transformations. Les informations sensibles, telles que les mots de passe des options de connexion, continuent d'être supprimées.

Si les informations requises ne sont pas fournies à votre demande, Amazon Q placera des espaces réservés, dans lesquels vous devrez mettre à jour le code généré avec les valeurs appropriées avant d'exécuter le code.

Vous trouverez ci-dessous des exemples d'utilisation de la connaissance du contexte.

Exemple : interactions

Lire un fichier Amazon S3 et écrire dans un compartiment Amazon S3

Prompt: Create an AWS Glue spark job that reads a file s3://amzn-s3-demo-bucket-input-bucket-name/input-filename.csv and saves it into the parquet file under directory s3://amzn-s3-demo-bucket-output-bucket-name/output-s3-prefix/

```
import sys
from awsglue.transforms import *
from pyspark.context import SparkContext
from pyspark.sql import SparkSession

sc = SparkContext.getOrCreate()
spark = SparkSession.builder.getOrCreate()

# Script generated for node S3DataSource
```



```
S3DataSource_dsource1 = spark.read.format("csv").load(
    "s3://amzn-s3-demo-bucket-input-bucket-name/input-filename.csv"
)

# Script generated for node S3DataSink
S3DataSource_dsource1.write.format("parquet").mode("append").save(
    "s3://amzn-s3-demo-bucket-output-bucket-name/output-s3-prefix/"
)
```

The screenshot displays the AWS Glue console on the left and the Amazon Q interface on the right. The AWS Glue console shows a sidebar with navigation options like 'Getting started', 'Data Catalog', and 'Data integration and ETL'. The main content area includes sections for 'Prepare your account for AWS Glue', 'Catalog and search for datasets', 'Move and transform data', 'Resources and tutorials', and 'Data integration and management'. The Amazon Q interface on the right features a chat window with the message 'Hello! I'm Amazon Q, your AWS generative AI assistant.' and a text input field for asking questions about AWS services.

Récupérez les données de Lakehouse et écrivez-les dans la base de données

Prompt: write an ETL script to read from a Lakehouse table my-table in database my-database and write it to a RDS MySQL table my-target-table

Pour les champs où vous n'avez pas fourni d'informations (par exemple, le nom de connexion requis est pour le récepteur de données MySQL et contient par défaut un espace réservé <connection-name> dans le code généré), un espace réservé est conservé pour que vous puissiez renseigner les informations requises avant d'exécuter le script.

Script généré :

```
import sys
from awsglue.transforms import *
from pyspark.context import SparkContext
```

```

from pyspark.sql import SparkSession
from connectivity.adapter import CatalogConnectionHelper

sc = SparkContext.getOrCreate()
spark = SparkSession.builder.getOrCreate()

# Script generated for node S3DataSource
S3DataSource_dsource1 = spark.read.format("parquet").load(
    "s3://amzn-lakehouse-demo-bucket/my-database/my-table"
)

# Script generated for node ConnectionV2DataSink
ConnectionV2DataSink_dsink1_additional_options = {"dbtable": "my-target-table"}
CatalogConnectionHelper(spark).write(
    S3DataSource_dsource1,
    "mysql",
    "<connection-name>",
    ConnectionV2DataSink_dsink1_additional_options,
)

```

The screenshot displays the AWS Glue console. The main area features a 'Welcome to AWS Glue' banner with a 'Get started' button. Below the banner are three primary action cards: 'Prepare your account for AWS Glue' (with a 'Set up roles and users' button), 'Catalog and search for datasets' (with a 'Go to the Data Catalog' button), and 'Move and transform data' (with buttons for 'Go to Zero-ETL integrations' and 'Go to ETL jobs'). A 'Resources and tutorials' section lists various guides and documentation. The 'Data integration and management' section provides links for monitoring jobs, connecting to data stores, orchestrating pipelines, and managing data quality. A 'What's new in Glue' section highlights recent updates. On the right, the 'Amazon Q' sidebar is visible, featuring a chat interface with the message 'Hello! I'm Amazon Q, your AWS generative AI assistant.' and a search bar for asking questions about AWS services.

Exemple : flux de travail ETL complet

L'exemple suivant montre comment vous pouvez demander à AWS Glue de créer un script AWS Glue pour terminer un flux de travail ETL complet avec l'invite suivante : Create a AWS Glue ETL

Script read from two AWS Glue Data Catalog tables venue and event in my database glue_db_4fthqih3vvk1if, join the results on the field venueid, filter on venue state with condition as venuestate=='DC' after joining the results and write output to an Amazon S3 S3 location s3://amz-s3-demo-bucket/output/ in CSV format

Le flux de travail comprend la lecture à partir de différentes sources de données (deux tables AWS Glue Data Catalog) et quelques transformations après la lecture en joignant le résultat de deux lectures, en filtrant en fonction de certaines conditions et en écrivant la sortie transformée dans une destination Amazon S3 au format CSV.

La tâche générée renseignera les informations détaillées sur la source de données, les opérations de transformation et de réception avec les informations correspondantes extraites de la question de l'utilisateur, comme ci-dessous.

```
import sys
from awsglue.transforms import *
from pyspark.context import SparkContext
from pyspark.sql import SparkSession

sc = SparkContext.getOrCreate()
spark = SparkSession.builder.getOrCreate()


# Script generated for node CatalogDataSource
CatalogDataSource_dsource1 = spark.sql("select * from
`glue_db_4fthqih3vvk1if`.`venue`")

# Script generated for node CatalogDataSource
CatalogDataSource_dsource2 = spark.sql("select * from
`glue_db_4fthqih3vvk1if`.`event`")

# Script generated for node JoinTransform
JoinTransform_transform1 = CatalogDataSource_dsource1.join(
    CatalogDataSource_dsource2,
    (CatalogDataSource_dsource1["venueid"] == CatalogDataSource_dsource2["venueid"]),
    "inner",
)

# Script generated for node FilterTransform
FilterTransform_transform2 = JoinTransform_transform1.filter("venuestate=='DC'")
```

```
# Script generated for node S3DataSink
FilterTransform_transform2.write.format("csv").mode("append").save(
    "s3://amz-s3-demo-bucket/output//output/"
)
```



Limites

- Report du contexte :
 - La fonction de reconnaissance du contexte ne reporte que le contexte de la requête précédente de l'utilisateur au sein de la même conversation. Il ne conserve pas le contexte au-delà de la requête immédiatement précédente.
- Support pour les configurations de nœuds :
 - À l'heure actuelle, la reconnaissance du contexte ne prend en charge qu'un sous-ensemble des configurations requises pour les différents nœuds.
 - Support pour les champs facultatifs est prévu dans les prochaines versions.
- Disponibilité :
 - La connaissance du contexte et le DataFrame support sont disponibles dans les blocs-notes Q Chat et SageMaker Unified Studio. Toutefois, ces fonctionnalités ne sont pas encore disponibles dans les blocs-notes AWS Glue Studio.

Orchestration dans AWS Glue

Les sections suivantes vous renseignent sur l'orchestration d'applications dans AWS Glue.

Rubriques

- [Démarrage des tâches et des crawlers à l'aide de déclencheurs](#)
- [Réalisation d'activités ETL complexes à l'aide de plans et de flux de travail dans AWS Glue](#)
- [Élaboration de plans dans AWS Glue](#)

Démarrage des tâches et des crawlers à l'aide de déclencheurs

Entrée AWS Glue, vous pouvez créer des objets du catalogue de données appelés déclencheurs, que vous pouvez utiliser pour démarrer manuellement ou automatiquement un ou plusieurs robots d'exploration ou pour extraire, transformer et charger (ETL) des tâches. À l'aide de déclencheurs, vous pouvez concevoir une chaîne de tâches et d'crawlers dépendants.

Note

Vous pouvez accomplir la même chose en définissant des flux de travail. Les flux de travail sont préférables pour créer des opérations ETL multitâches complexes. Pour de plus amples informations, veuillez consulter [the section called “Exécution d'activités ETL complexes à l'aide de plans et de flux de travail”](#).

Rubriques

- [AWS Glue déclencheurs](#)
- [Ajout de déclencheurs](#)
- [Activation et désactivation des déclencheurs](#)

AWS Glue déclencheurs

Lorsqu'il est lancé, un déclencheur peut démarrer des tâches et des crawlers spécifiés. Il se déclenche à la demande en fonction d'une planification ou d'une combinaison d'événements.

 Note

Seuls deux crawlers peuvent être activés par un même déclencheur. Si vous souhaitez analyser plusieurs magasins de données, utilisez plusieurs sources pour chaque crawler au lieu d'exécuter plusieurs crawlers simultanément.

Un déclencheur peut exister dans différents états : CREATED, ACTIVATED ou DEACTIVATED. Il peut aussi passer par des états transitoires, comme ACTIVATING. Pour arrêter temporairement le lancement d'un déclencheur, vous pouvez le désactiver. Vous pourrez le réactiver ultérieurement.

Il existe trois types de tâches :

Planifié

Déclencheur temporel basé sur `cron`.

Vous pouvez créer un déclencheur pour un ensemble de tâches ou de crawlers en fonction d'une planification. Vous pouvez spécifier des contraintes, telles que la fréquence d'exécution des tâches ou des crawlers, les jours de la semaine qu'ils s'exécutent et à quelle heure. Ces contraintes sont basées sur `cron`. Lorsque vous configurez la planification d'un déclencheur, prenez en compte les fonctions et limitations de `cron`. Par exemple, si vous choisissez d'exécuter votre crawler le 31 de chaque mois, n'oubliez pas que certains mois ne comportent pas 31 jours. Pour plus d'informations sur `cron`, consultez [Planifications temporelles pour les tâches et les crawlers](#).

Conditionnel

Déclencheur qui se lance lorsqu'une ou plusieurs tâches précédentes, ou encore un ou plusieurs crawlers précédents satisfont à une liste de conditions.

Lorsque vous créez un déclencheur conditionnel, vous spécifiez une liste de tâches et une liste de crawlers à surveiller. Pour chaque tâche surveillée ou crawler, vous spécifiez un état à surveiller, tel que réussite, échec, expiré, etc. Le déclencheur se lance si les tâches ou les crawlers surveillés se finalisent par les statuts spécifiés. Vous pouvez configurer le déclencheur pour qu'il se lance lorsque tout ou partie des événements surveillés se produisent.

Par exemple, vous pouvez configurer un déclencheur T1 pour démarrer la tâche J3 lorsque la tâche J1 et la tâche J2 sont terminées avec succès, et un autre déclencheur T2 pour démarrer la tâche J4 si la tâche J1 ou la tâche J2 échoue.

Le tableau suivant répertorie les états de fin de tâche et de crawler qui déclenchent la surveillance.

États d'achèvement des tâches	États d'achèvement des crawlers
• SUCCEEDED • STOPPED • FAILED • TIMEOUT	• SUCCEEDED • FAILED • CANCELLED

A la demande

Déclencheur qui se lance lorsque vous l'activez. Les déclencheurs à la demande ne peuvent pas comporter l'état DEACTIVATED ou ACTIVATED. Ils restent toujours à l'état CREATED.

Afin qu'ils soient prêts à se déclencher dès qu'ils existent, vous pouvez définir un indicateur pour activer les déclencheurs planifiés et conditionnels lors de leur création.

Important

Les tâches ou les crawlers qui s'exécutent à la suite de l'exécution d'autres tâches ou crawlers sont considérés comme dépendants. Les tâches ou les crawlers dépendants ne sont lancés que si la tâche ou le crawler qui se finalise a été démarré par un déclencheur. Toutes les tâches d'une chaîne de dépendance doivent descendre d'un seul calendrier ou d'un déclencheur à la demande.

Transmission de paramètres de tâches avec des déclencheurs

Un déclencheur permet de transmettre des paramètres aux tâches qu'il démarre. Ceux-ci incluent les arguments des tâches, la valeur de délai d'attente, la configuration de sécurité, etc. Si le déclencheur démarre plusieurs tâches, les paramètres sont transmis à chacune d'elles.

Voici les règles pour les arguments de tâche transmis par un déclencheur :

- Si la clé de la paire clé-valeur correspond à un argument de tâche par défaut, l'argument transmis remplace l'argument par défaut. Si la clé ne correspond pas à un argument par défaut, l'argument est transmis en tant qu'argument supplémentaire pour la tâche.
- Si la clé de la paire clé-valeur correspond à un argument non remplaçable, l'argument transmis est ignoré.

Pour plus d'informations, consultez [the section called “Déclencheurs”](#) le AWS Glue API.

Ajout de déclencheurs

Vous pouvez ajouter un déclencheur à l'aide du AWS Glue console, le AWS Command Line Interface (AWS CLI) ou le AWS Glue API.

Note

À l'heure actuelle, le AWS Glue la console ne prend en charge que les tâches, et non les robots d'exploration, lorsque vous travaillez avec des déclencheurs. Vous pouvez utiliser le AWS CLI ou AWS Glue API permettant de configurer des déclencheurs à la fois avec des jobs et des crawlers.

Pour ajouter un déclencheur (console)

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous ETL, choisissez Triggers (Déclencheurs). Choisissez Add trigger (Ajouter un déclencheur).
3. Fournissez les propriétés suivantes :

Nom

Attribuez un nom unique à votre déclencheur.

Type de déclencheur

Spécifiez l'un des éléments suivants :

- Schedule (Planification) : le déclencheur se lance à une fréquence et à une heure spécifiques.

- Job Events (Événements de tâche) : déclencheur conditionnel. Le déclencheur est exécuté lorsqu'une ou plusieurs tâches de la liste correspondent à l'événement de tâche sélectionné. Pour que le déclencheur s'exécute, les tâches surveillées doivent avoir été lancées par des déclencheurs. Pour chaque tâche que vous choisirez, vous ne pouvez surveiller qu'un événement de tâche (état d'achèvement).
 - On-demand (À la demande) : le déclencheur se lance lorsqu'il est activé.
4. Terminez l'assistant de déclenchement. Sur la page Review (Vérifier), vous pouvez activer immédiatement les déclencheurs Schedule (Planification) et Job events (Événements de tâche) (conditionnels) en sélectionnant Enable trigger on creation (Activer le déclencheur lors de la création).

Pour ajouter un déclencheur (AWS CLI)

- Utilisez une commande similaire à la suivante.

```
aws glue create-trigger --name MyTrigger --type SCHEDULED --schedule "cron(0 12 * * ? *)" --actions CrawlerName=MyCrawler --start-on-creation
```

Cette commande crée un déclencheur de planification nommé `MyTrigger`, qui s'exécute tous les jours à 12h00 UTC et démarre un crawler nommé `MyCrawler`. Le déclencheur est créé dans l'état activé.

Pour de plus amples informations, veuillez consulter [the section called “AWS Glue déclencheurs”](#).

Planifications temporelles pour les tâches et les crawlers

Vous pouvez définir une planification temporelle pour vos crawlers et vos tâches dans AWS Glue. La définition de ces planifications utilise la syntaxe de type Unix [cron](#). Vous spécifiez l'heure en [heure UTC](#), et la précision minimale d'une planification est de 5 minutes.

Pour en savoir plus sur la configuration des tâches et des crawlers à exécuter à l'aide d'une planification, veuillez consulter [Démarrage des tâches et des crawlers à l'aide de déclencheurs](#).

Expressions Cron

Ces expressions se composent de six champs obligatoires qui sont séparés par des espaces.

Syntaxe

```
cron(Minutes Hours Day-of-month Month Day-of-week Year)
```

Champs	Valeurs	Caractères génériques
Minutes	0–59	, - * /
Heures	0 – 23	, - * /
D ay-of-month	1–31	, - * ? / L W
Mois	1–12 ou JAN–DEC	, - * /
D ay-of-week	1–7 ou dim.–sam.	, - * ? / L
Année	1970-2199	, - * /

Caractères génériques

- Le caractère générique , (virgule) inclut des valeurs supplémentaires. Dans le champ Month, JAN, FEB, MAR contiendrait janvier, février et mars.
- Le caractère générique - (tiret) spécifie des plages. Dans le champ Day, 1–15 inclurait les jours 1 à 15 du mois spécifié.
- Le caractère générique * (astérisque) inclut toutes les valeurs du champ. Dans le champ Hours, * inclut chaque heure.
- Le caractère générique / (barre oblique) spécifie les incréments. Dans le champ Minutes, vous pouvez saisir **1/10** pour spécifier un dixième de minute, en démarrant de la première minute de l'heure (par exemple, les 11e, 21e et 31e minutes).
- Le caractère générique ? (point d'interrogation) indique l'un ou l'autre. Dans le Day-of-month champ, tu pouvais saisir 7, et si tu ne te souciais pas du jour de la semaine le septième, tu pourrais entrer ? sur le Day-of-week terrain.
- Le caractère générique L dans les champs ou spécifie le dernier jour du mois ou de la semaine.Day-of-monthDay-of-week
- Le caractère générique W dans le champ spécifie un jour de la semaine. Day-of-month Dans le champ Day-of-month, 3W spécifie le jour le plus proche du troisième jour de semaine du mois.

Limites

- Vous ne pouvez pas spécifier les champs Day-of-month et Day-of-week de la même expression cron. Si vous spécifiez une valeur dans l'un de ces champs, vous devez utiliser un signe ? (point d'interrogation) dans l'autre.
- Les expressions cron qui entraînent des fréquences d'une rapidité supérieure à 5 minutes ne sont pas prises en charge.

Exemples

Lors de la création d'une planification, vous pouvez utiliser les exemples de chaînes cron suivants.

Minutes	Heures	Jour du mois	Mois	Jour de la semaine	Année	Signification
0 USD	10	*	*	?	*	Exécuter à 10 h 00 (UTC) chaque jour
15	12	*	*	?	*	Exécuter à 12 h 15 (UTC) chaque jour
0	18	?	*	MON-FRI	*	Exécuter à 18 h 00 (UTC) du lundi au vendredi
0	8	1	*	?	*	Exécuter à 8 h 00 (UTC) chaque

Minutes	Heures	Jour du mois	Mois	Jour de la semaine	Année	Signification
						1er jour du mois
0/15	*	*	*	?	*	Exécuter toutes les 15 minutes
0/10	*	?	*	MON-FRI	*	Exécuter toutes les 10 minutes du lundi au vendredi
0/5	8–17	?	*	MON-FRI	*	Exécuter toutes les 5 minutes du lundi au vendredi entre 8 h 00 et 17 h 55 (UTC)

Par exemple, pour une exécution quotidienne à 12 h 15 UTC, spécifiez :

```
cron(15 12 * * ? *)
```

Activation et désactivation des déclencheurs

Vous pouvez activer ou désactiver un déclencheur à l'aide du AWS Glue console, le AWS Command Line Interface (AWS CLI) ou le AWS Glue API.

Pour activer ou désactiver un déclencheur (console)

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous ETL, choisissez Triggers (Déclencheurs).
3. Activez la case à cocher en regard du déclencheur souhaité et, dans le menu Action, choisissez Enable trigger (Activer le déclencheur) pour activer le déclencheur ou Disable trigger (Désactiver le déclencheur) pour désactiver le déclencheur.

Pour activer ou désactiver un déclencheur (AWS CLI)

- Entrez l'une des commandes suivantes.

```
aws glue start-trigger --name MyTrigger  
  
aws glue stop-trigger --name MyTrigger
```

Le démarrage d'un déclencheur l'active, tandis que l'arrêt d'un déclencheur le désactive. Lorsque vous activez un déclencheur à la demande, il s'exécute immédiatement.

Pour de plus amples informations, veuillez consulter [the section called “AWS Glue déclencheurs”](#).

Réalisation d'activités ETL complexes à l'aide de plans et de flux de travail dans AWS Glue

Il est préférable de mettre en œuvre certains des processus complexes d'extraction, de transformation et de chargement (ETL) de votre organisation en utilisant plusieurs processus dépendants AWS Glue jobs et crawlers. Utilisation AWS Glue flux de travail, vous pouvez concevoir un processus ETL complexe multi-tâches et multi-crawler qui AWS Glue peut être exécuté et suivi en tant qu'entité unique. Une fois que vous avez créé un flux de travail et spécifié les tâches, les crawlers et les déclencheurs dans le flux de travail, vous pouvez exécuter le flux de travail à la demande ou selon un planning.

Rubriques

- [Vue d'ensemble des flux de travail dans AWS Glue](#)
- [Création et développement manuels d'un flux de travail dans AWS Glue](#)

- [Démarrage d'un AWS Glue flux de travail avec un EventBridge événement Amazon](#)
- [Afficher les EventBridge événements qui ont lancé un flux de travail](#)
- [Exécution et surveillance d'un flux de travail dans AWS Glue](#)
- [Arrêt d'une exécution de flux de travail](#)
- [Réparation et reprise de l'exécution d'un flux de travail](#)
- [Obtenir et définir les propriétés d'exécution du flux de travail dans AWS Glue](#)
- [Interrogation des flux de travail à l'aide du AWS Glue API](#)
- [Plan directeur et restrictions de flux de travail dans AWS Glue](#)
- [Résolution des erreurs de plan dans AWS Glue](#)
- [Autorisations pour les personas et les rôles pour AWS Glue plans](#)

Vue d'ensemble des flux de travail dans AWS Glue

Entrée AWS Glue, vous pouvez utiliser des flux de travail pour créer et visualiser des activités complexes d'extraction, de transformation et de chargement (ETL) impliquant plusieurs robots d'exploration, tâches et déclencheurs. Chaque flux de travail gère l'exécution et la surveillance de l'ensemble de ses tâches et crawlers. Tandis qu'un flux de travail exécute chaque composant, il enregistre le statut et la progression de l'exécution. Vous trouverez ainsi une présentation de la tâche la plus volumineuses et les détails de chaque étape. Le AWS Glue la console fournit une représentation visuelle d'un flux de travail sous forme de graphique.

Vous pouvez créer un flux de travail à partir d'un AWS Glue plan, ou vous pouvez créer manuellement un flux de travail, un composant à la fois, à l'aide du AWS Management Console ou du AWS Glue API. Pour plus d'informations sur les modèles de présentation, consultez [the section called "Présentation des plans"](#).

Les déclencheurs dans les flux de travail peuvent démarrer les tâches ou les crawlers, et peuvent être déclenchés lorsque les tâches et les crawlers ont terminé leurs opérations. En utilisant des déclencheurs, vous pouvez créer de grandes chaînes de tâches et d'crawlers interdépendants. En plus des déclencheurs au sein d'un flux de travail qui définissent les dépendances des tâches et de l'crawler, chaque flux de travail a un déclencheur de démarrage. Il existe trois types de déclencheurs :

- **Schedule (Planification)** - le flux de travail est démarré selon un planificateur que vous définissez. La planification peut être quotidienne, hebdomadaire, mensuelle, etc., ou peut être une planification personnalisée basée sur une expression cron.

- À la demande — Le flux de travail est lancé manuellement à partir du AWS Glue console, API ou AWS CLI.
- EventBridge événement — Le flux de travail est lancé lors de la survenance d'un seul EventBridge événement Amazon ou d'un lot d' EventBridge événements Amazon. Avec ce type de déclencheur, AWS Glue peut être un consommateur d'événements dans une architecture axée sur les événements. Tout type EventBridge d'événement peut démarrer un flux de travail. L'arrivée d'un nouvel objet dans un compartiment Amazon S3 (l'opération `PutObject S3`) fait partie des cas d'utilisation les plus courants.

Démarrer un flux de travail avec un lot d'événements signifie attendre qu'un nombre spécifié d'événements ait été reçu ou qu'un laps de temps spécifié se soit écoulé. Lorsque vous créez le déclencheur EventBridge d'événement, vous pouvez éventuellement spécifier les conditions du lot. Si vous spécifiez des conditions de lot, vous devez spécifier la taille du lot (nombre d'événements) et pouvez éventuellement spécifier une fenêtre de lot (nombre de secondes). La fenêtre de lot par défaut et maximale est de 900 secondes (15 minutes). La condition de lot qui est remplie démarre en premier le flux de travail. La fenêtre de traitement par lots démarre lorsque le premier événement arrive. Si vous ne spécifiez pas de conditions de lot lors de la création d'un déclencheur, la taille du lot par défaut est 1.

Lorsque le flux de travail démarre, les conditions du lot sont réinitialisées et le déclencheur d'événement commence à surveiller la prochaine condition de lot à remplir pour redémarrer le flux de travail.

Le tableau suivant montre comment la taille du lot et la fenêtre de lot fonctionnent ensemble pour déclencher un flux de travail.

Taille de lot	Fenêtre de lot	Condition de déclenchement obtenue
10		Le flux de travail est déclenché à l'arrivée de 10 EventBridge événements, ou 15 minutes après l'arrivée du premier événement, selon la première éventualité. (Si la taille de la fenêtre temporelle n'est pas spécifiée, la valeur par défaut est de 15 minutes.)
10	2 min	Le flux de travail est déclenché à l'arrivée de 10 EventBridge événements, ou 2 minutes après l'arrivée du premier événement, selon la première éventualité.

Taille de lot	Fenêtre de lot	Condition de déclenchement obtenue
1		Le flux de travail est déclenché dès l'arrivée du premier événement. La taille de la fenêtre n'est pas pertinente. La taille du lot est définie par défaut sur 1 si vous ne spécifiez pas les conditions du lot lorsque vous créez le déclencheur EventBridge d'événement.

L'opération d'API `GetWorkflowRun` renvoie la condition de lot qui a déclenché le flux de travail.

Quel que soit le mode de démarrage d'un flux de travail, vous pouvez spécifier le nombre maximal d'exécutions simultanées de flux de travail lorsque vous créez le flux de travail.

Si un événement ou un lot d'événements démarre une exécution de flux de travail qui échoue finalement, cet événement ou lot d'événements n'est plus pris en compte pour démarrer une exécution de flux de travail. Une nouvelle exécution de flux de travail est démarrée uniquement lorsque le prochain événement ou lot d'événements se présente.

Important

Limitez le nombre total de tâches, de crawlers et de déclencheurs au sein d'un flux de travail à 100 ou moins. Si vous en incluez plus de 100, vous risquez de rencontrer des erreurs lorsque vous tentez de reprendre ou d'arrêter les exécutions du flux de travail.

Une exécution de flux de travail ne démarrera pas si elle dépasse la limite de simultanéité définie pour le flux de travail, même si la condition d'événement est remplie. Il est conseillé d'ajuster les limites de simultanéité des flux de travail en fonction du volume d'événements attendu. AWS Glue ne réessaie pas les exécutions de flux de travail qui échouent en raison du dépassement des limites de simultanéité. De même, il est conseillé d'ajuster les limites de simultanéité pour les tâches et les crawlers dans les flux de travail en fonction du volume d'événements attendu.


Propriétés de l'exécution du flux de travail

Pour partager et gérer l'état tout au long de l'exécution d'un flux de travail, vous pouvez définir des propriétés d'exécution de flux de travail par défaut. Ces propriétés, qui sont des paires nom/valeur, sont disponibles pour toutes les tâches du flux de travail. À l'aide de AWS Glue API, les tâches

peuvent récupérer les propriétés d'exécution du flux de travail et les modifier pour les tâches qui seront ajoutées ultérieurement dans le flux de travail.

Graphique de flux de travail

L'image suivante montre le graphique d'un flux de travail très basique sur AWS Glue console. Votre flux de travail peut avoir des douzaines de composants.



Ce flux de travail est démarré par un déclencheur de calendrier, Month-close1, qui lance deux tâches, De-duplicate et Fix phone numbers. Lorsque vous avez validé les deux tâches, un déclencheur d'événement, Fix/De-dupe succeeded, lance un crawler, Update schema.

Affichages de flux de travail statiques et dynamiques

Pour chaque flux de travail, il existe la notion de vue statique et de vue dynamique. La conception statique indique la conception du flux de travail. L'affichage dynamique est une vue de l'exécution qui inclut les dernières informations d'exécution pour chacune des tâches et chacun des crawlers. Les informations d'exécution inclut le statut de succès et les informations détaillées d'erreur.

Lorsqu'un flux de travail est en cours d'exécution, la console affiche la vue dynamique, indiquant graphiquement les tâches qui se sont terminées et celles qu'il reste à exécuter. Vous pouvez

également extraire la vue dynamique d'un flux de travail en cours d'exécution avec AWS Glue API. Pour de plus amples informations, veuillez consulter [Interrogation des flux de travail à l'aide du AWS Glue API](#).

 Consultez aussi

- [the section called “Création d'un flux de travail à partir d'un plan”](#)
- [the section called “Création et développement d'un flux de travail manuellement”](#)
- [Flux de travail](#) (pour l'API de flux de travail)

Création et développement manuels d'un flux de travail dans AWS Glue

Vous pouvez utiliser le plugin AWS Glue console pour créer et développer manuellement un flux de travail, un nœud à la fois.

Un flux de travail contient des tâches, des crawlers et des déclencheurs. Avant de créer un flux de travail manuellement, créez les tâches et les crawlers que le flux de travail doit inclure. Il est préférable de spécifier des robots d'run-on-demand exploration pour les flux de travail. Vous pouvez créer de nouveaux déclencheurs lors du développement de votre flux de travail ou vous pouvez cloner des déclencheurs existants dans le flux de travail. Lorsque vous clonez un déclencheur, tous les objets du catalogue associés au déclencheur (les tâches ou les crawlers qui le déclenchent et les tâches ou les crawlers qu'il démarre) sont ajoutés au flux de travail.

 Important

Limitez le nombre total de tâches, de crawlers et de déclencheurs au sein d'un flux de travail à 100 ou moins. Si vous en incluez plus de 100, vous risquez de rencontrer des erreurs lorsque vous tentez de reprendre ou d'arrêter les exécutions du flux de travail.

Vous développez votre flux de travail en ajoutant des déclencheurs au graphique du flux de travail et en définissant les événements et les actions observés pour chaque déclencheur. Vous commencez par un déclencheur de début, qui peut être un déclencheur à la demande ou un déclencheur de planification, et complétez le graphique en ajoutant des déclencheurs d'événements (conditionnels).

Étape 1 : Créer le flux de travail

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous ETL, sélectionnez Workflows (Flux de travail).
3. Sélectionnez Add workflow (Ajouter un flux de travail) et remplissez le formulaire Add a new ETL workflow (Ajouter un nouveau flux de travail ETL).

Toutes les propriétés d'exécution par défaut facultatives que vous ajoutez sont rendues disponibles en tant qu'arguments à toutes les tâches du flux de travail. Pour de plus amples informations, veuillez consulter [Obtenir et définir les propriétés d'exécution du flux de travail dans AWS Glue](#).

4. Sélectionnez Add workflow (Ajouter un flux de travail).

Le nouveau flux de travail s'affiche dans la liste sur la page Workflows (Flux de travail).

Étape 2 : Ajouter un déclencheur de début

1. Sur la page Workflows (Flux de travail), sélectionnez votre nouveau flux de travail. Ensuite, en bas de la page, assurez-vous que l'onglet Graph (Graphique) est sélectionné.
2. Choisissez Add trigger (Ajouter un déclencheur), puis, dans la boîte de dialogue Add trigger (Ajouter un déclencheur), effectuez l'une des actions suivantes :

- Choisissez Clone existing (Clone existant), puis choisissez un déclencheur à cloner. Choisissez ensuite Ajouter.

Le déclencheur s'affiche sur le graphique, ainsi que les tâches et les crawlers qu'il surveille, et les tâches et les crawlers qu'il démarre.

Si vous avez sélectionné par erreur le mauvais déclencheur, sélectionnez le déclencheur sur le graphique, puis choisissez Remove (Supprimer).

- Choisissez Add new (Ajouter un nouveau) et complétez le formulaire Add trigger (Ajouter un déclencheur).

1. Pour le type de déclencheur, sélectionnez Planification, À la demande ou EventBridge événement.


Pour le type de déclencheur Schedule (Planification), sélectionnez l'une des options Frequency (Fréquence). Sélectionnez Custom (Personnalisée) pour saisir une expression cron.

Pour un EventBridge événement de type déclencheur, entrez Nombre d'événements (taille du lot) et entrez éventuellement Délai (fenêtre de lot). Si vous omettez Time delay (Délai), la fenêtre de lot est définie par défaut sur 15 minutes. Pour de plus amples informations, veuillez consulter [Vue d'ensemble des flux de travail dans AWS Glue](#).

2. Choisissez Ajouter.

Le déclencheur s'affiche sur le graphique, ainsi qu'un nœud d'espace réservé (nommé Add node (Ajouter un nœud)). Dans l'exemple ci-dessous, le déclencheur de démarrage est un déclencheur de planification nommé Month-close1.

À ce stade, le déclencheur n'est pas encore enregistré.



3. Si vous avez ajouté un nouveau déclencheur, procédez comme suit :
 - a. Effectuez l'une des actions suivantes :
 - Choisissez le nœud d'espace réservé (Add node (Ajouter un nœud)).
 - Assurez-vous que le déclencheur de début est sélectionné, et sur le menu Action au-dessus du graphique, choisissez Add jobs/crawlers to trigger (Ajouter des tâches/crawlers au déclencheur).

- b. Dans la boîte de dialogue Add jobs(s) and crawler(s) to trigger (Ajouter des tâches et des crawlers au déclencheur), sélectionnez une ou plusieurs tâches ou crawlers, puis sélectionnez Add (Ajouter).

Le déclencheur est enregistré, et les tâches ou crawlers sélectionnés apparaissent sur le graphique avec les connecteurs du déclencheur.

Si vous avez ajouté par erreur les mauvaises tâches ou les mauvais crawlers, vous pouvez sélectionner le déclencheur ou un connecteur et choisir Remove (Supprimer).

Étape 3 : Ajouter d'autres déclencheurs

Continuez de développer votre flux de travail en ajoutant d'autres déclencheurs de type Event (Événement). Pour faire un zoom avant ou arrière ou pour agrandir le canevas du graphique, utilisez les icônes à la droite du graphique. Pour chaque déclencheur à ajouter, effectuez les opérations suivantes :

Note

Il n'existe aucune action pour enregistrer le flux de travail. Après avoir ajouté votre dernier déclencheur et affecté des actions au déclencheur, le flux de travail est terminé et enregistré. Vous pouvez toujours revenir plus tard et ajouter plus de nœuds.

1. Effectuez l'une des actions suivantes :

- Pour cloner un déclencheur existant, assurez-vous qu'aucun nœud sur le graphique ne soit sélectionné, et sur le menu Action, choisissez Add trigger (Ajouter un déclencheur).
- Pour ajouter un nouveau déclencheur qui surveille une tâche particulière ou un crawler particulier sur le graphique, sélectionnez le nœud de la tâche ou de l'crawler, puis choisissez le nœud d'espace réservé Add trigger (Ajouter un déclencheur).

Vous pouvez ajouter d'autres tâches ou crawlers à surveiller pour ce déclencheur dans une étape ultérieure.

2. Dans la boîte de dialogue Add trigger (Ajouter un déclencheur), exécutez l'une des actions suivantes :

- Choisissez Add new (Ajouter un nouveau) et complétez le formulaire Add trigger (Ajouter un déclencheur). Choisissez ensuite Ajouter.

Le déclencheur s'affiche sur le graphique. Vous complèterez le déclencheur lors d'une étape ultérieure.

- Choisissez Clone existing (Clone existant), puis choisissez un déclencheur à cloner. Choisissez ensuite Ajouter.


Le déclencheur s'affiche sur le graphique, ainsi que les tâches et les crawlers qu'il surveille, et les tâches et les crawlers qu'il démarre.

Si vous avez choisi par erreur le mauvais déclencheur, sélectionnez le déclencheur sur le graphique, puis choisissez Remove (Supprimer).

3. Si vous avez ajouté un nouveau déclencheur, procédez comme suit :

- a. Sélectionnez le nouveau déclencheur.

Comme l'illustre le graphique suivant, le déclencheur De-dupe/fix succeeded est sélectionné et les nœuds d'espace réservé apparaissent pour (1) les événements à surveiller et pour (2) les actions.



- b. (Facultatif si le déclencheur surveille déjà un événement et que vous souhaitez ajouter davantage de tâches ou d'crawlers à surveiller.) Choisissez le nœud events-to-watch

réservé, puis dans la boîte de dialogue Ajouter des tâches et des robots d'exploration à surveiller, sélectionnez un ou plusieurs travaux ou robots d'exploration. Choisissez un événement à surveiller (SUCCEEDED, FAILED, etc.), puis choisissez Add (Ajouter).

- c. Assurez-vous que le déclencheur est sélectionné, puis choisissez le nœud d'espace réservé des actions.
- d. Dans la boîte de dialogue Add job(s) and crawler(s) to watch (Ajouter des tâches et des crawlers à surveiller) sélectionnez une ou plusieurs tâches ou un ou plusieurs crawlers, et choisissez Add (Ajouter).

Les tâches et les crawlers sélectionnés apparaissent sur le graphique, avec les connecteurs du déclencheur.

Pour en savoir plus sur les flux de travail et les plans, consultez les rubriques suivantes.

- [Vue d'ensemble des flux de travail dans AWS Glue](#)
- [Exécution et surveillance d'un flux de travail dans AWS Glue](#)
- [Création d'un flux de travail à partir d'un plan dans AWS Glue](#)

Démarrage d'un AWS Glue flux de travail avec un EventBridge événement Amazon

Amazon EventBridge, également connu sous le nom d' CloudWatch Events, vous permet d'automatiser vos AWS services et de répondre automatiquement aux événements du système tels que les problèmes de disponibilité des applications ou les modifications des ressources. Les événements AWS liés aux services sont diffusés EventBridge en temps quasi réel. Vous pouvez écrire des règles simples pour indiquer quels événements vous intéressent et les actions automatisées à effectuer quand un événement correspond à une règle.

Avec EventBridge du soutien, AWS Glue peut servir de producteur et de consommateur d'événements dans une architecture axée sur les événements. Pour les flux de travail, AWS Glue soutient tout type d' EventBridge événement en tant que consommateur. Le cas d'utilisation le plus courant est l'arrivée d'un nouvel objet dans un compartiment Amazon S3. Si vous avez des données arrivant à des intervalles irréguliers ou indéfinis, vous pouvez traiter ces données aussi près que possible de leur arrivée.

 Note

AWS Glue ne garantit pas la livraison des EventBridge messages. AWS Glue n'effectue aucune déduplication s'il EventBridge délivre des messages dupliqués. Vous devez gérer l'idempotence en fonction de votre cas d'utilisation.

Assurez-vous de configurer correctement EventBridge les règles pour éviter d'envoyer des événements indésirables.

Avant de commencer

Si vous souhaitez démarrer un flux de travail avec des événements de données Amazon S3, vous devez vous assurer que les événements du compartiment S3 qui vous intéressent sont enregistrés dans AWS CloudTrail et EventBridge. Pour ce faire, vous devez créer un CloudTrail parcours. Pour plus d'informations, consultez [la section Création d'un historique pour votre AWS compte](#).

Pour démarrer un flux de travail avec un EventBridge événement

 Note

Dans les commandes suivantes, remplacez :

- *<workflow-name>* avec le nom à attribuer au flux de travail.
- *<trigger-name>* avec le nom à attribuer au déclencheur.
- *<bucket-name>* avec le nom du compartiment Amazon S3.
- *<account-id>* avec un identifiant de AWS compte valide.
- *<region>* avec le nom de la région (par exemple, us-east-1).
- *<rule-name>* avec le nom à attribuer à la EventBridge règle.

1. Assurez-vous que vous disposez des autorisations AWS Identity and Access Management (IAM) nécessaires pour créer et afficher les EventBridge règles et les cibles. Voici un modèle de politique de clé que vous pouvez attacher. Vous voudrez peut-être restreindre sa portée afin d'imposer des limites aux opérations et aux ressources.

```
{  
  "Version": "2012-10-17",  
  "Statement": [  

```



```

    {
      "Effect": "Allow",
      "Action": [
        "events:PutRule",
        "events:DisableRule",
        "events>DeleteRule",
        "events:PutTargets",
        "events:RemoveTargets",
        "events:EnableRule",
        "events:List*",
        "events:Describe*"
      ],
      "Resource": "*"
    }
  ]
}

```

2. Créez un rôle IAM que le EventBridge service peut assumer lorsqu'il transmet un événement à AWS Glue.
 - a. Sur la page Création d'un rôle de la console IAM, sélectionnez Service AWS . Choisissez ensuite le service CloudWatch Events.
 - b. Suivez intégralement l'assistant de Création d'un rôle. L'Assistant attache automatiquement les politiques CloudWatchEventsBuiltInTargetExecutionAccess et CloudWatchEventsInvocationAccess.
 - c. Attachez la politique en ligne suivante au rôle. Cette politique permet au EventBridge service de diriger les événements vers AWS Glue.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:notifyEvent"
      ],
      "Resource": [
        "arn:aws:glue:<region>:<account-id>:workflow/<workflow-name>"
      ]
    }
  ]
}

```

```
}
```

3. Saisissez la commande suivante pour créer le flux de travail.

Veillez consulter la rubrique [create-workflow](#) dans la Référence des commandes AWS CLI pour plus d'informations sur les paramètres de ligne de commande facultatifs supplémentaires.

```
aws glue create-workflow --name <workflow-name>
```

4. Entrez la commande suivante pour créer un déclencheur d' EventBridge événement pour le flux de travail. Ce sera le déclencheur de démarrage du flux de travail. Remplacez *<actions>* par les actions à effectuer (les tâches et les robots d'exploration pour démarrer).

Veillez consulter la rubrique [create-trigger](#) dans la Référence des commandes AWS CLI pour obtenir des informations sur la manière de coder les arguments actions.

```
aws glue create-trigger --workflow-name <workflow-name> --type EVENT --  
name <trigger-name> --actions <actions>
```

Si vous souhaitez que le flux de travail soit déclenché par un lot d'événements plutôt que par un seul EventBridge événement, entrez plutôt la commande suivante.

```
aws glue create-trigger --workflow-name <workflow-name> --type EVENT  
--name <trigger-name> --event-batching-condition BatchSize=<number-of-  
events>,BatchWindow=<seconds> --actions <actions>
```

En ce qui concerne les arguments event-batching-condition, BatchSize est obligatoire et BatchWindow est facultatif. Si BatchWindow est omis, la fenêtre est définie par défaut à 900 secondes, ce qui correspond à la taille maximale de la fenêtre.

Exemple

L'exemple suivant crée un déclencheur qui démarre le eventtest flux de travail après l'arrivée de trois EventBridge événements, ou cinq minutes après l'arrivée du premier événement, selon la première éventualité.

```
aws glue create-trigger --workflow-name eventtest --type EVENT --name objectArrival  
--event-batching-condition BatchSize=3,BatchWindow=300 --actions JobName=test1
```

5. Créez une règle sur Amazon EventBridge.

- a. Créer l'objet JSON définissant les détails de la règle dans votre éditeur de texte préféré.

L'exemple suivant spécifie Amazon S3 comme source d'événement, PutObject comme nom de l'événement, et le nom du compartiment en tant que paramètre de requête. Cette règle démarre un flux de travail lorsqu'un nouvel objet arrive dans le compartiment.

```
{
  "source": [
    "aws.s3"
  ],
  "detail-type": [
    "AWS API Call via CloudTrail"
  ],
  "detail": {
    "eventSource": [
      "s3.amazonaws.com"
    ],
    "eventName": [
      "PutObject"
    ],
    "requestParameters": {
      "bucketName": [
        "<bucket-name>"
      ]
    }
  }
}
```

Pour démarrer le flux de travail lorsqu'un nouvel objet arrive dans un dossier du compartiment, vous pouvez introduire le code suivant dans requestParameters.

```
"requestParameters": {
  "bucketName": [
    "<bucket-name>"
  ]
  "key" : [{ "prefix" : "<folder1>/<folder2>/*"}]}
}
```

- b. Utilisez votre outil préféré pour convertir l'objet JSON de définition de règle en une chaîne échappée.

```
{\n  \"source\": [\n    \"aws.s3\"\n  ],\n  \"detail-type\": [\n    \"AWS API\n    Call via CloudTrail\"\n  ],\n  \"detail\": {\n    \"eventSource\": [\n      \"s3.amazonaws.com\"\n    ],\n    \"eventName\": [\n      \"PutObject\"\n    ],\n    \"requestParameters\": {\n      \"bucketName\": [\n        \"<bucket-  
name>\"\n      ]\n    }\n  }
```

- c. Exécutez la commande suivante pour créer un modèle de paramètre JSON que vous pouvez modifier afin de spécifier les paramètres d'entrée d'une commande `put-rule` ultérieure. Enregistrez le résultat dans un fichier. Dans cet exemple, le fichier est nommé `ruleCommand`.

```
aws events put-rule --name <rule-name> --generate-cli-skeleton >ruleCommand
```

Pour de plus amples informations sur le paramètre `--generate-cli-skeleton`, veuillez consulter la rubrique [Génération du squelette AWS CLI et des paramètres d'entrée à partir d'un fichier d'entrée JSON ou YAML](#) dans le Guide de l'utilisateur de l'interface de ligne de commande AWS .

Le fichier de sortie devrait ressembler à ce qui suit.

```
{
  "Name": "",
  "ScheduleExpression": "",
  "EventPattern": "",
  "State": "ENABLED",
  "Description": "",
  "RoleArn": "",
  "Tags": [
    {
      "Key": "",
      "Value": ""
    }
  ],
  "EventBusName": ""
}
```

- d. Modifiez le fichier pour supprimer éventuellement des paramètres et pour spécifier au minimum les paramètres `Name`, `EventPattern` et `State`. Pour le paramètre `EventPattern`, fournissez la chaîne d'échappement des détails de règle que vous avez créé à l'étape précédente.

```
{
  "Name": "<rule-name>",
  "EventPattern": "{\n  \"source\": [\n    \"aws.s3\"\n  ],\n  \"detail-type\": [\n    \"AWS API Call via CloudTrail\"\n  ],\n  \"detail\": {\n    \"eventSource\": [\n      \"s3.amazonaws.com\"\n    ],\n    \"eventName\": [\n      \"PutObject\"\n    ],\n    \"requestParameters\": {\n      \"bucketName\": [\n        \"<bucket-name>\"\n      ]\n    }\n  }\n}",
  "State": "DISABLED",
  "Description": "Start an AWS Glue workflow upon new file arrival in an Amazon S3 bucket"
}
```

 Note

Il est préférable de laisser la règle désactivée jusqu'à ce que vous ayez terminé la création du flux de travail.

- e. Saisissez la commande `put-rule` suivante, qui lit les paramètres d'entrée dans le fichier `ruleCommand`.

```
aws events put-rule --name <rule-name> --cli-input-json file://ruleCommand
```

La sortie suivante indique que l'opération a réussi.

```
{
  "RuleArn": "<rule-arn>"
}
```

6. Saisissez la commande suivante pour attacher la règle à une cible. La cible est le flux de travail dans AWS Glue. `<role-name>` Remplacez-le par le rôle que vous avez créé au début de cette procédure.

```
aws events put-targets --rule <rule-name> --targets
  "Id"="1", "Arn"="arn:aws:glue:<region>:<account-id>:workflow/<workflow-name>", "RoleArn"="arn:aws:iam::<account-id>:role/<role-name>" --region <region>
```

La sortie suivante indique que l'opération a réussi.

```
{
```

```
"FailedEntryCount": 0,  
"FailedEntries": []  
}
```

7. Confirmez la connexion réussie de la règle et de la cible en saisissant la commande suivante.

```
aws events list-rule-names-by-target --target-arn arn:aws:glue:<region>:<account-id>:workflow/<workflow-name>
```

Le résultat suivant indique un succès, où *<rule-name>* est le nom de la règle que vous avez créée.

```
{  
  "RuleNames": [  
    "<rule-name>"  
  ]  
}
```

8. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
9. Sélectionnez le flux de travail et vérifiez que le déclencheur de démarrage et ses actions (les tâches ou les crawlers qu'il démarre) apparaissent sur le graphique du flux de travail. Procédez ensuite comme indiqué dans [Étape 3 : Ajouter d'autres déclencheurs](#). Vous pouvez également ajouter d'autres composants au flux de travail à l'aide du AWS Glue API ou AWS Command Line Interface.
10. Lorsque le flux de travail est entièrement défini, activez la règle.

```
aws events enable-rule --name <rule-name>
```

Le flux de travail est maintenant prêt à être lancé par un EventBridge événement ou un lot d'événements.

 Consultez aussi

- [Guide de EventBridge l'utilisateur Amazon](#)
- [Vue d'ensemble des flux de travail dans AWS Glue](#)

- [Création et développement manuels d'un flux de travail dans AWS Glue](#)

Afficher les EventBridge événements qui ont lancé un flux de travail

Vous pouvez consulter l'ID de l' EventBridge événement Amazon qui a lancé votre flux de travail. Si votre flux de travail a été lancé par un lot d'événements, vous pouvez afficher l'événement IDs de tous les événements du lot.

Pour les flux de travail dont la taille de lot est supérieure à un, vous pouvez également voir quelle condition de lot a démarré le flux de travail : l'arrivée du nombre d'événements dans la taille du lot ou l'expiration de la fenêtre de lot.

Pour afficher les EventBridge événements qui ont lancé un flux de travail (console)

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous ETL, sélectionnez Workflows (Flux de travail).
3. Sélectionnez un flux de travail. Puis, en bas, sélectionnez l'onglet History (Historique).
4. Sélectionnez un flux de travail, puis sélectionnez View run details (Afficher les détails de l'exécution).
5. Sur la page de détails de l'exécution, repérez le champ Run properties (Propriétés d'exécution), et recherchez la clé aws:eventIds.

La valeur de cette clé est une liste d' EventBridge événements IDs.

Pour afficher les EventBridge événements qui ont démarré un flux de travail (AWS API)

- Incluez le code suivant dans votre script Python.

```
workflow_params =  
    glue_client.get_workflow_run_properties(Name=workflow_name, RunId=workflow_run_id)  
batched_events = workflow_params['aws:eventIds']
```

batched_events sera une liste de chaînes, chaque chaîne étant un ID d'événement.

 Consultez aussi

- [Guide de EventBridge l'utilisateur Amazon](#)
- [the section called “Présentation des flux de travail”](#)

Exécution et surveillance d'un flux de travail dans AWS Glue

Si le déclencheur de démarrage d'un flux de travail est un déclencheur à la demande, vous pouvez démarrer le flux de travail à partir du AWS Glue console. Procédez comme suit pour exécuter et surveiller un flux de travail. Si le flux de travail échoue, vous pouvez afficher le graphique d'exécution pour déterminer le nœud qui a échoué. Pour faciliter le dépannage, si le flux de travail a été créé à partir d'un modèle, vous pouvez afficher l'exécution ce dernier pour voir les valeurs des paramètres de modèle qui ont été utilisées pour créer le flux de travail. Pour de plus amples informations, veuillez consulter [the section called “Affichage des exécutions de plans”](#).

Vous pouvez exécuter et surveiller un flux de travail à l'aide du AWS Glue console, API ou AWS Command Line Interface (AWS CLI).

Pour exécuter et surveiller un flux de travail (console)

1. Ouvrez la AWS Glue console à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous ETL, sélectionnez Workflows (Flux de travail).
3. Sélectionnez un flux de travail. Dans le menu Actions, choisissez Run (Exécuter).
4. Vérifiez la colonne Last run status (Statut de la dernière exécution) dans la liste des flux de travail. Cliquez sur le bouton Refresh (Actualiser) pour afficher le statut du flux de travail en cours.
5. Pendant l'exécution du flux de travail ou une fois qu'il est terminé (ou a échoué), affichez les détails de l'exécution en effectuant les étapes suivantes.
 - a. Assurez-vous que le flux de travail est sélectionné, puis sélectionnez l'onglet History (Historique).
 - b. Choisissez l'exécution de flux de travail actuelle ou la plus récente, puis sélectionnez View run details (Afficher les détails de l'exécution).

Le graphique d'exécution du flux de travail affiche l'état d'exécution actuel.

 - c. Choisissez n'importe quel nœud dans le graphique pour afficher ses détails et son état.

Graph

Select the graph nodes to resume and then choose Resume run.

Legend: ✔ Completed 🔄 Running ✖ Failed ⚠ Warning ❌ Error

Job details

Selected run

Tue, 21 Jul 2020 19:55:10 GMT - FAILED

Name	myDemoBPWorkflow1_etl_jo
Description	-
Job run id	jr_8e74182b093deea6bf63d
Status	Failed
Resume	☐
Retry attempt	-
Job run error	Error: Invalid argument type

Execution time: 28
 Start time: Tue, 21 Jul 2020 19:55:10 G
 End time: Tue, 21 Jul 2020 20:21:17 G

Pour exécuter et surveiller un flux de travail (AWS CLI)

1. Entrez la commande suivante. Remplacez *<workflow-name>* par le flux de travail à exécuter.

```
aws glue start-workflow-run --name <workflow-name>
```

Si le flux de travail est démarré avec succès, la commande renvoie l'ID d'exécution.

2. Affichez le statut d'exécution du flux de travail à l'aide de la commande `get-workflow-run`. Indiquez le nom et l'ID d'exécution du flux de travail.

```
aws glue get-workflow-run --name myWorkflow --run-id  
wr_d2af14217e8eae775ba7b1fc6fc7a42c795aed3cbcd8763f9415452e2dbc8705
```

Voici un exemple de sortie de commande.

```
{
  "Run": {
    "Name": "myWorkflow",
    "WorkflowRunId":
"wr_d2af14217e8eae775ba7b1fc6fc7a42c795aed3cbcd8763f9415452e2dbc8705",
    "WorkflowRunProperties": {
      "run_state": "COMPLETED",
      "unique_id": "fee63f30-c512-4742-a9b1-7c8183bdaae2"
    },
    "StartedOn": 1578556843.049,
    "CompletedOn": 1578558649.928,
    "Status": "COMPLETED",
```

```
    "Statistics": {
      "TotalActions": 11,
      "TimeoutActions": 0,
      "FailedActions": 0,
      "StoppedActions": 0,
      "SucceededActions": 9,
      "RunningActions": 0,
      "ErroredActions": 0
    }
  }
}
```

 Voir aussi :

- [the section called “Présentation des flux de travail”](#)
- [the section called “Présentation des plans”](#)

Arrêt d'une exécution de flux de travail

Vous pouvez utiliser le plugin AWS Glue console, AWS Command Line Interface (AWS CLI) ou AWS Glue API pour arrêter l'exécution d'un flux de travail. Lorsque vous arrêtez un cycle de flux de travail, toutes les tâches et tous les crawlers en cours d'exécution sont immédiatement arrêtés, tandis que ceux qui n'ont pas encore été lancés ne démarreront jamais. Cela peut prendre jusqu'à une minute pour que toutes les tâches et tous les crawlers en cours d'exécution s'arrêtent. L'état du cycle de flux de travail passe de Running (Exécution en cours) à Stopping (Arrêt en cours), puis lorsque le cycle de flux de travail est complètement arrêté, l'état passe à Stopped (Arrêté).

Une fois le cycle de flux de travail arrêté, vous pouvez afficher le graphique d'exécution pour voir les tâches et les crawlers abandonnés, ainsi que ceux qui n'ont jamais démarré. Vous pouvez ensuite déterminer si vous devez prendre des mesures spécifiques pour garantir l'intégrité des données. L'arrêt d'un cycle de flux de travail n'entraîne aucune opération de restauration automatique.

Pour arrêter l'exécution d'un flux de travail (console)

1. Ouvrez la AWS Glue console à l'adresse <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sous ETL, sélectionnez Workflows (Flux de travail).
3. Choisissez un flux de travail en cours d'exécution, puis choisissez l'onglet History (Historique).

4. Choisissez le cycle de flux de travail, puis choisissez Stop run (Arrêter ce cycle).

L'état d'exécution passe à Stopping (Arrêt en cours).

5. (Facultatif) Choisissez le cycle de flux de travail, puis (Optional) Choose the workflow run, choose (Afficher les détails de l'exécution) et consultez le graphique d'exécution.

Pour arrêter un cycle de flux de travail (AWS CLI)

- Entrez la commande suivante. Remplacez *<workflow-name>* par le nom du flux de travail et *<run-id>* par l'ID d'exécution du flux de travail à arrêter.

```
aws glue stop-workflow-run --name <workflow-name> --run-id <run-id>
```

Voici un exemple de la commande stop-workflow-run.

```
aws glue stop-workflow-run --name my-workflow --run-id  
wr_137b88917411d128081069901e4a80595d97f719282094b7f271d09576770354
```

Réparation et reprise de l'exécution d'un flux de travail


Si un ou plusieurs nœuds (tâches ou crawlers) d'un flux de travail ne se terminent pas correctement, cela signifie que le flux de travail n'a été exécuté que partiellement. Après avoir trouvé les causes premières et apporté des corrections, vous pouvez sélectionner un ou plusieurs nœuds à partir desquels reprendre l'exécution du flux de travail, puis reprendre celle-ci. Les nœuds sélectionnés et tous les nœuds en aval de ces nœuds sont ensuite exécutés.

Rubriques

- [Reprise d'une exécution de flux de travail : comment ça marche](#)
- [Reprise de l'exécution d'un flux de travail](#)
- [Remarques et limitations pour la reprise des exécutions de flux de travail](#)

Reprise d'une exécution de flux de travail : comment ça marche


Examinez le flux de travail W1 dans le diagramme suivant.



L'exécution de flux de travail se déroule comme suit :

1. Le déclencheur T1 démarre la tâche J1.
2. La réussite de la tâche J1 déclenche T2 et T3, qui exécutent les tâches J2 et J3, respectivement.
3. Les tâches J2 et J3 échouent.
4. Les déclencheurs T4 et T5 dépendent de la réussite de J2 et J3, ils ne se déclenchent donc pas et les tâches J4 et J5 ne s'exécutent pas. Le flux de travail W1 n'est exécuté que partiellement.

À présent, supposons que les problèmes qui ont causé l'échec de J2 et J3 sont corrigés. J2 et J3 sont sélectionnés comme points de départ à partir desquels reprendre l'exécution du flux de travail.



L'exécution de flux de travail reprend comme suit :

1. Les tâches J2 et J3 sont exécutées avec succès.
2. Déclenche T4 et T5.
3. Les tâches J4 et J5 sont exécutées avec succès.

La reprise de l'exécution du flux de travail est suivie en tant qu'exécution de flux de travail distincte avec un nouvel ID d'exécution. Lorsque vous affichez l'historique du flux de travail, vous pouvez afficher l'ID d'exécution précédente pour toute exécution de flux de travail. Dans l'exemple de la capture d'écran suivante, le flux de travail exécuté avec l'ID d'exécution `wr_c7a22...` (la deuxième

ligne) avait un nœud qui ne s'est pas terminé. L'utilisateur a résolu le problème et a repris l'exécution du flux de travail, ce qui a entraîné l'ID d'exécution `wr_a07e55...` (la première ligne).

Graph Details History				
View run details Stop run 				
	Run ID	Previous run ID	Run status	Execution time
	<code>wr_a07e55f2087afdd415a404403f644a4265278...</code>	<code>wr_c7a2219a8dc412f1366a5b30df3c58be30b9...</code>	Completed	17 Minutes
	<code>wr_c7a2219a8dc412f1366a5b30df3c58be30b9...</code>	-	Completed	8 Minutes

Note

Pour le reste de cette discussion, le terme « reprise de l'exécution du flux de travail » fait référence à l'exécution du flux de travail qui a été créée lors de la reprise de l'exécution du flux de travail précédente. L'« exécution du flux de travail d'origine » fait référence à l'exécution du flux de travail qui n'a été exécutée que partiellement et qui devait être reprise.

Graphique de la reprise d'une l'exécution du flux de travail

Dans une exécution de flux de travail reprise, bien que seul un sous-ensemble de nœuds soit exécuté, le graphique d'exécution est un graphique complet. Autrement dit, les nœuds qui ne se sont pas exécutés dans le flux de travail repris sont copiés à partir du graphique d'exécution de l'exécution du flux de travail d'origine. Les nœuds de tâche et d'crawler copiés qui ont été exécutés dans l'exécution du flux de travail d'origine incluent les détails de l'exécution.

Considérez à nouveau le flux de travail W1 dans le diagramme précédent. Lorsque l'exécution du flux de travail reprend en commençant par J2 et J3, le graphique d'exécution de l'exécution de flux de travail reprise affiche tous les travaux, J1 à J5, et tous les déclencheurs, T1 à T5. Les détails de l'exécution pour J1 sont copiés à partir de l'exécution du flux de travail d'origine.

Instantanés d'exécution de flux de travail

Lorsqu'une exécution de flux de travail est lancée, AWS Glue prend un instantané du graphe de conception du flux de travail à ce moment-là. Cet instantané est utilisé pendant toute la durée de l'exécution du flux de travail. Si vous apportez des modifications à des déclencheurs après le démarrage de l'exécution, ces modifications n'affectent pas l'exécution du flux de travail en cours. Les instantanés garantissent que les exécutions du flux de travail se déroulent de manière cohérente.

Les instantanés rendent les déclencheurs inaltérables uniquement. Les modifications que vous apportez aux tâches en aval et aux crawlers pendant l'exécution du flux de travail prennent effet pour l'exécution en cours.

Reprise de l'exécution d'un flux de travail

Procédez comme suit pour reprendre l'exécution d'un flux de travail. Vous pouvez reprendre l'exécution d'un flux de travail à l'aide du AWS Glue console, API ou AWS Command Line Interface (AWS CLI).

Pour reprendre l'exécution d'un flux de travail (console)

1. Ouvrez la AWS Glue console à l'adresse <https://console.aws.amazon.com/glue/>.

Connectez-vous en tant qu'utilisateur autorisé à afficher les flux de travail et à reprendre les exécutions de flux de travail.

Note

Pour reprendre les exécutions de flux de travail, vous devez disposer de l'autorisation `glue:ResumeWorkflowRun` AWS Identity and Access Management (IAM).

2. Dans le panneau de navigation, sous ETL, sélectionnez Workflows (Flux de travail).
3. Sélectionnez un flux de travail, puis l'onglet History (Historique).
4. Sélectionnez l'exécution du flux de travail qui n'a été exécutée que partiellement, puis sélectionnez View run details (Afficher les détails de l'exécution).
5. Dans le graphique d'exécution, sélectionnez le premier (ou le seul) nœud que vous souhaitez redémarrer et à partir duquel vous souhaitez reprendre l'exécution du flux de travail.
6. Dans le volet de détails à droite du graphique, cochez la case Resume (Reprendre).

The screenshot shows the AWS Glue console interface. On the left, a workflow graph is displayed with three nodes: a green circle node labeled 'myDemoBPWorkflow1_start...', a red square node labeled 'myDemoBPWorkflow1_etl_j...', and a grey diamond node labeled 'myDemoBPWorkflow1_myD...'. The red square node is highlighted with a blue border and a red 'X' icon in the top right corner. A legend at the top left indicates: Completed (green checkmark), Running (blue refresh icon), Failed (red X), Warning (yellow triangle), and Error (red circle with X). A 'Resume run' button is visible in the top right. On the right, the 'Job details' panel shows the 'Selected run' as 'Tue, 21 Jul 2020 19:55:10 GMT - FAILED'. The job name is 'myDemoBPWorkflow1_etl_jo', the job run ID is 'jr_8e74182b093deea6bf63d', the status is 'Failed', and the error message is 'Error: Invalid argument type'.

Le nœud change de couleur et affiche une petite icône de CV en haut à droite.

This screenshot shows the same workflow graph after the 'Resume' action. The red square node is now purple and has a small 'C' icon in the top right corner. The 'Job details' panel on the right shows the 'Selected run' as 'Tue, 21 Jul 2020 19:55:10 GMT - RESUME'. The status is now 'Resume', and the 'Resume' checkbox is checked.

7. Effectuez les deux étapes précédentes pour redémarrer tous les nœuds supplémentaires.
8. Sélectionnez Resume (Reprendre l'exécution).

Pour reprendre l'exécution d'un flux de travail (AWS CLI)

1. Assurez-vous de disposer de l'autorisation IAM `glue:ResumeWorkflowRun`.
2. Récupérez le nœud IDs pour les nœuds que vous souhaitez redémarrer.
 - a. Exécutez la commande `get-workflow-run` pour l'exécution du flux de travail d'origine. Fournissez le nom du flux de travail et l'ID d'exécution, puis ajoutez l'option `--include-graph`, comme illustré dans l'exemple suivant. Obtenez l'ID d'exécution dans l'onglet History (Historique) de la console ou en exécutant la commande `get-workflow`.

```
aws glue get-workflow-run --name cloudtrailtest1 --run-id  
wr_a07e55f2087afdd415a404403f644a4265278f68b13ba3da08c71924ebe3c3a8 --include-  
graph
```

La commande renvoie les nœuds et les bords du graphique sous la forme d'un objet JSON volumineux.

- b. Localisez les nœuds qui vous intéressent avec les propriétés Type et Name des objets de nœud.

Ce qui suit est un exemple d'objet nœud de la sortie.

```
{  
  "Type": "JOB",  
  "Name": "test1_post_failure_4592978",  
  "UniqueId":  
    "wnode_d1b2563c503078b153142ee76ce545fe5ceef66e053628a786ddd74a05da86fd",  
  "JobDetails": {  
    "JobRuns": [  
      {  
        "Id":  
          "jr_690b9f7fc5cb399204bc542c6c956f39934496a5d665a42de891e5b01f59e613",  
        "Attempt": 0,  
        "TriggerName": "test1_aggregate_failure_649b2432",  
        "JobName": "test1_post_failure_4592978",  
        "StartedOn": 1595358275.375,  
        "LastModifiedOn": 1595358298.785,  
        "CompletedOn": 1595358298.785,  
        "JobRunState": "FAILED",  
        "PredecessorRuns": [],  
        "AllocatedCapacity": 0,  
        "ExecutionTime": 16,  
        "Timeout": 2880,  
        "MaxCapacity": 0.0625,  
        "LogGroupName": "/aws-glue/python-jobs"  
      }  
    ]  
  }  
}
```

- c. Obtenez l'ID de nœud à partir de la propriété UniqueId de l'objet nœud.

3. Exécutez la commande `resume-workflow-run`. Indiquez le nom du flux de travail, l'ID d'exécution et la liste des nœuds IDs séparés par des espaces, comme indiqué dans l'exemple suivant.

```
aws glue resume-workflow-run --name cloudtrailtest1 --run-id
wr_a07e55f2087afdd415a404403f644a4265278f68b13ba3da08c71924ebe3c3a8 --node-
ids wnode_ca1f63e918fb855e063aed2f42ec5762ccf71b80082ae2eb5daeb8052442f2f3
wnode_d1b2563c503078b153142ee76ce545fe5ceef66e053628a786ddd74a05da86fd
```

La commande génère l'ID d'exécution de la (nouvelle) exécution de flux de travail reprise et une liste de nœuds qui seront démarrés.

```
{
  "RunId": "wr_2ada0d3209a262fc1156e4291134b3bd643491bcfb0ceead30bd3e4efac24de9",
  "NodeIds": [
    "wnode_ca1f63e918fb855e063aed2f42ec5762ccf71b80082ae2eb5daeb8052442f2f3"
  ]
}
```

Notez que bien que l'exemple de commande `resume-workflow-run` répertorie deux nœuds à redémarrer, l'exemple de sortie indiquait qu'un seul nœud serait redémarré. C'est parce qu'un nœud était en aval de l'autre nœud, et le nœud en aval serait redémarré de toute façon par le flux normal du flux de travail.

Remarques et limitations pour la reprise des exécutions de flux de travail

Gardez les notes et limitations suivantes à l'esprit lors de la reprise des exécutions du flux de travail.

- Vous pouvez reprendre l'exécution d'un flux de travail uniquement s'il est dans l'état **COMPLETED**.

Note

Même si un ou plusieurs nœuds d'une exécution de flux de travail ne se terminent pas, l'état d'exécution du flux de travail est affiché sous la forme **COMPLETED**. Assurez-vous de vérifier le graphique d'exécution pour découvrir tous les nœuds qui ne se sont pas terminés avec succès.

- Vous pouvez reprendre une exécution de flux de travail à partir de n'importe quel tâche ou nœud d'crawler que l'exécution de flux de travail d'origine a tenté d'exécuter. Vous ne pouvez pas reprendre un flux de travail exécuté à partir d'un nœud déclencheur.
- Le redémarrage d'un nœud ne réinitialise pas son état. Toutes les données partiellement traitées ne sont pas annulées.
- Vous pouvez reprendre le même flux de travail plusieurs fois. Si une exécution de flux de travail reprise s'exécute partiellement, vous pouvez résoudre le problème et reprendre l'exécution.
- Si vous sélectionnez deux nœuds à redémarrer et qu'ils dépendent l'un de l'autre, le nœud en amont est exécuté avant le nœud en aval. En fait, la sélection du nœud en aval est redondante, car elle sera exécutée selon le flux normal du flux de travail.

Obtenir et définir les propriétés d'exécution du flux de travail dans AWS Glue

Utilisez les propriétés d'exécution du flux de travail pour partager et gérer l'état des tâches de votre AWS Glue flux de travail. Vous pouvez définir les propriétés d'exécution par défaut lorsque vous créez le flux de travail. Ensuite, tandis que vos tâches s'exécutent, elles peuvent récupérer les valeurs des propriétés d'exécution et, le cas échéant, les modifier pour les entrées de tâches qui sont plus loin dans le flux de travail. Lorsqu'une tâche modifie une propriété d'exécution, la nouvelle valeur existe uniquement pour l'exécution du flux de travail. Les propriétés d'exécution par défaut ne sont pas affectées.

Si votre tâche AWS Glue ne fait pas partie d'un flux de travail, ces propriétés ne seront pas définies.

L'exemple de code Python suivant à partir d'une tâche d'extraction, de transformation et de chargement (ETL) montre comment obtenir les propriétés d'exécution des flux de travail.

```
import sys
import boto3
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from awsglue.context import GlueContext
from pyspark.context import SparkContext

glue_client = boto3.client("glue")
args = getResolvedOptions(sys.argv, ['JOB_NAME', 'WORKFLOW_NAME', 'WORKFLOW_RUN_ID'])
workflow_name = args['WORKFLOW_NAME']
workflow_run_id = args['WORKFLOW_RUN_ID']
```

```
workflow_params = glue_client.get_workflow_run_properties(Name=workflow_name,
                                                         RunId=workflow_run_id)["RunProperties"]

target_database = workflow_params['target_database']
target_s3_location = workflow_params['target_s3_location']
```

Le code suivant continue en définissant la propriété d'exécution `target_format` sur `'csv'`.

```
workflow_params['target_format'] = 'csv'
glue_client.put_workflow_run_properties(Name=workflow_name, RunId=workflow_run_id,
                                       RunProperties=workflow_params)
```

Pour plus d'informations, consultez les ressources suivantes :

- [GetWorkflowRunProperties action \(Python : `get\_workflow\_run\_properties`\)](#)
- [PutWorkflowRunProperties action \(Python : `put\_workflow\_run\_properties`\)](#)

Interrogation des flux de travail à l'aide du AWS Glue API

AWS Glue fournit une API riche pour gérer les flux de travail. Vous pouvez récupérer la vue statique ou dynamique d'un flux de travail en cours d'exécution à l'aide de l' AWS Glue API. Pour de plus amples informations, veuillez consulter [Flux de travail](#).

Rubriques

- [Interrogation des vues statiques](#)
- [Interrogation des vues dynamiques](#)

Interrogation des vues statiques

Utilisez l'opération d'API `GetWorkflow` pour obtenir une vue statique qui indique la conception d'un flux de travail. Cette opération renvoie un graphe orienté composé de nœuds et d'arcs, où un nœud représente un déclencheur, une tâche ou un crawler. Les arcs définissent les relations entre les nœuds. Ils sont représentés par des connecteurs (flèches) sur le graphique du AWS Glue console.

Vous pouvez également utiliser cette opération avec des bibliothèques de traitement de graphes populaires telles que NetworkX, igraph, JGraph T et le framework Java Universal Network/Graph (JUNG). Étant donné que toutes ces bibliothèques représentent les graphiques de la même manière, des transformations minimales sont nécessaires.

La vue statique renvoyée par cette API est la plus grande up-to-date vue selon la dernière définition des déclencheurs associés au flux de travail.

Définition du graphique

Un graphe G de flux de travail est une paire ordonnée (N, E) , où N est un ensemble de nœuds et E un ensemble d'arcs. Un nœud est un sommet du graphique identifié par un numéro unique. Un nœud peut être de type déclencheur, tâche ou crawler. Par exemple : `{name:T1, type:Trigger, uniqueId:1}`, `{name:J1, type:Job, uniqueId:2}`.

Un arc est un 2-tuplet de la forme $(src, dest)$, où src et $dest$ sont les nœuds et il y a un arc dirigé de src vers $dest$.

Exemple d'interrogation d'une vue statique

Envisagez un déclencheur conditionnel T , qui déclenche la tâche $J2$ après la fin de la tâche $J1$.

```
J1 ---> T ---> J2
```

Nœuds : $J1, T, J2$

Arcs : $(J1, T), (T, J2)$

Interrogation des vues dynamiques

Utilisez l'opération `APIGetWorkflowRun` pour obtenir une vue dynamique d'un flux de travail en cours d'exécution. Cette opération renvoie la même vue statique du graphe en même temps que les métadonnées relatives à l'exécution du flux de travail.

Pour l'exécution, les nœuds représentent les tâches dans l'appel `GetWorkflowRun` ont une liste d'exécutions de tâches lancées dans le cadre de la dernière exécution du flux de travail. Vous pouvez utiliser cette liste pour afficher le statut d'exécution de chaque tâche dans le graphique lui-même. Pour les dépendances en aval qui ne sont pas encore exécutées, ce champ est défini sur `null`. Le graphique d'informations vous permet de connaître l'état actuel d'un flux de travail à tout moment.

La vue dynamique renvoyée par cette API est basée sur la vue statique qui était présente lorsque l'exécution du flux de travail a été démarrée.

Exemple de nœuds d'exécution : `{name:T1, type: Trigger, uniqueId:1}, {name:J1, type:Job, uniqueId:2, jobDetails:{jobRuns}}, {name:C1, type:Crawler, uniqueId:3, crawlerDetails:{crawls}}`

Exemple 1 : Vue dynamique

L'exemple suivant illustre un simple flux de travail à deux déclencheurs.

- Nœuds : t1, j1, t2, j2
- Arcs : (t1, j1), (j1, t2), (t2, j2)

La réponse GetWorkflow contient les éléments suivants.

```
{
  Nodes : [
    {
      "type" : Trigger,
      "name" : "t1",
      "uniqueId" : 1
    },
    {
      "type" : Job,
      "name" : "j1",
      "uniqueId" : 2
    },
    {
      "type" : Trigger,
      "name" : "t2",
      "uniqueId" : 3
    },
    {
      "type" : Job,
      "name" : "j2",
      "uniqueId" : 4
    }
  ],
  Edges : [
    {
      "sourceId" : 1,
      "destinationId" : 2
    },
    {
      "sourceId" : 2,
      "destinationId" : 3
    },
    {

```

```
        "sourceId" : 3,  
        "destinationId" : 4  
    }  
}
```

La réponse `GetWorkflowRun` contient les éléments suivants.

```
{  
  Nodes : [  
    {  
      "type" : Trigger,  
      "name" : "t1",  
      "uniqueId" : 1,  
      "jobDetails" : null,  
      "crawlerDetails" : null  
    },  
    {  
      "type" : Job,  
      "name" : "j1",  
      "uniqueId" : 2,  
      "jobDetails" : [  
        {  
          "id" : "jr_12334",  
          "jobRunState" : "SUCCEEDED",  
          "errorMessage" : "error string"  
        }  
      ],  
      "crawlerDetails" : null  
    },  
    {  
      "type" : Trigger,  
      "name" : "t2",  
      "uniqueId" : 3,  
      "jobDetails" : null,  
      "crawlerDetails" : null  
    },  
    {  
      "type" : Job,  
      "name" : "j2",  
      "uniqueId" : 4,  
      "jobDetails" : [  
        {  
          "id" : "jr_1233sdf4",
```

```

        "jobRunState" : "SUCCEEDED",
        "errorMessage" : "error string"
      }
    ],
    "crawlerDetails" : null
  }
],
Edges : [
  {
    "sourceId" : 1,
    "destinationId" : 2
  },
  {
    "sourceId" : 2,
    "destinationId" : 3
  },
  {
    "sourceId" : 3,
    "destinationId" : 4
  }
]
}

```

Exemple 2 : Tâches multiples avec un déclencheur conditionnel

L'exemple suivant illustre un flux de travail avec plusieurs tâches et un déclencheur conditionnel (t3).

Consider Flow:

```

T(t1) ----> J(j1) ----> T(t2) ----> J(j2)
      |               |
      |               |
      >+-----> T(t3) <-----+
              |
              |
              J(j3)

```

Graph generated:

Nodes: t1, t2, t3, j1, j2, j3

Edges: (t1, j1), (j1, t2), (t2, j2), (j1, t3), (j2, t3), (t3, j3)

Plan directeur et restrictions de flux de travail dans AWS Glue

Les restrictions suivantes s'appliquent aux modèles et aux flux de travail.

Restrictions du plan

Gardez à l'esprit les restrictions de modèle suivantes :

- Le plan doit être enregistré dans la même AWS région que celle où réside le compartiment Amazon S3.
- Pour partager des plans entre AWS comptes, vous devez accorder les autorisations de lecture sur l'archive ZIP des plans dans Amazon S3. Les clients qui ont une autorisation de lecture sur une archive ZIP de plan peuvent enregistrer le plan dans leur AWS compte et l'utiliser.
- L'ensemble des paramètres de modèle est stocké en tant qu'objet JSON unique. La longueur maximale de cet objet est de 128 Ko.
- La taille maximale non compressée de l'archive ZIP du modèle est de 5 Mo. La taille maximale compressée est de 1 Mo.
- Limitez le nombre total de tâches, de crawlers et de déclencheurs au sein d'un flux de travail à 100 ou moins. Si vous en incluez plus de 100, vous risquez de rencontrer des erreurs lorsque vous tentez de reprendre ou d'arrêter les exécutions du flux de travail.

Restrictions du flux de travail

Gardez à l'esprit les restrictions de flux de travail suivantes. Certains de ces commentaires s'adressent davantage à un utilisateur qui crée des flux de travail manuellement.

- La taille de lot maximale pour un déclencheur d' EventBridge événement Amazon est de 100. La taille maximale de la fenêtre temporelle est de 900 secondes (15 minutes).
- Un déclencheur peut être associé à un seul flux de travail.
- Seul un déclencheur de départ (à la demande ou planifié) est autorisé.
- Si une tâche ou un crawler dans un flux de travail est démarré par un déclencheur qui se trouve en dehors du flux de travail, les déclencheurs intégrés au flux de travail et dépendant de l'achèvement (réussi ou non) de la tâche ou de l'crawler ne se déclenchent pas.
- De même, si une tâche ou un crawler dans un flux de travail comporte des déclencheurs qui dépendent de l'achèvement (avec succès ou non) d'une tâche ou d'un crawler à la fois dans et en dehors du flux de travail, si la tâche ou l'crawler est démarré à partir d'un flux de travail, seuls les déclencheurs à l'intérieur du flux de travail se déclenchent à l'achèvement de la tâche ou de l'crawler.

Résolution des erreurs de plan dans AWS Glue

Si vous rencontrez des erreurs lors de l'utilisation AWS Glue plans, utilisez les solutions suivantes pour vous aider à trouver la source des problèmes et à les résoudre.

Rubriques

- [Erreur : PySpark module manquant](#)
- [Error: missing blueprint config file \(Erreur : fichier de configuration de modèle manquant\)](#)
- [Error: missing imported file \(Erreur : fichier importé manquant\)](#)
- [Erreur : exécution non autorisée iamPassRole sur la ressource](#)
- [Error: invalid cron schedule \(Erreur : calendrier cron non valide\)](#)
- [Error: a trigger with the same name already exists \(Erreur : un déclencheur du même nom existe déjà\)](#)
- [Erreur : un flux de travail du même nom : foo existe déjà.](#)
- [Error: module not found in specified layoutGenerator path \(Erreur : module introuvable dans le chemin LayoutGenerator spécifié\)](#)
- [Error: validation error in Connections field \(Erreur : erreur de validation dans le champ Connections \[Connexions\]\)](#)

Erreur : PySpark module manquant

AWS Glue renvoie l'erreur « Erreur inconnue lors de l'exécution de la fonction de génération de mise en page ModuleNotFoundError : aucun module nommé 'pyspark' ».

Lorsque vous décompressez l'archive du modèle, cela peut ressembler à l'un des éléments suivants :

```
$ unzip compaction.zip
Archive:  compaction.zip
  creating: compaction/
  inflating: compaction/blueprint.cfg
  inflating: compaction/layout.py
  inflating: compaction/README.md
  inflating: compaction/compaction.py

$ unzip compaction.zip
Archive:  compaction.zip
  inflating: blueprint.cfg
  inflating: compaction.py
```

```
inflating: layout.py
inflating: README.md
```

Dans le premier cas, tous les fichiers liés au modèle ont été placés dans un dossier nommé `compaction` et il a ensuite été converti en un fichier zip nommé `compaction.zip`.

Dans le second cas, tous les fichiers requis pour le modèle n'étaient pas inclus dans un dossier et ont été ajoutés en tant que fichiers racine sous le fichier zip `compaction.zip`.

La création d'un fichier dans l'un des formats ci-dessus est autorisée. Assurez-vous toutefois que `blueprint.cfg` a le chemin d'accès approprié au nom de la fonction dans le script qui génère la mise en page.

Exemples

Dans le cas 1 : `blueprint.cfg` doit disposer de `layoutGenerator` comme suit :

```
layoutGenerator": "compaction.layout.generate_layout"
```

Dans le cas 2 : `blueprint.cfg` doit disposer de `layoutGenerator` comme suit :

```
layoutGenerator": "layout.generate_layout"
```

Si ce chemin n'est pas inclus correctement, vous pourriez voir une erreur comme indiqué. Par exemple, si vous avez la structure de dossiers mentionnée dans le cas 2 et que vous avez `layoutGenerator` comme indiquée dans le cas 1, vous pouvez voir l'erreur ci-dessus.

Error: missing blueprint config file (Erreur : fichier de configuration de modèle manquant)

AWS Glue renvoie l'erreur « Erreur inconnue lors de l'exécution de la fonction de génération de mise en page `FileNotFoundException` : [Errno 2] Aucun fichier ou répertoire de ce type : '/ tmp/compaction/blueprint .cfg' ».

Le `blueprint.cfg` doit être placé au niveau racine de l'archive ZIP ou dans un dossier portant le même nom que l'archive ZIP.

Lorsque nous extrayons l'archive ZIP de modèle, `blueprint.cfg` devrait se trouver dans l'un des chemins suivants. S'il ne se trouve pas dans l'un des chemins suivants, vous pouvez voir l'erreur ci-dessus.

```
$ unzip compaction.zip
Archive:  compaction.zip
  creating: compaction/
  inflating: compaction/blueprint.cfg

$ unzip compaction.zip
Archive:  compaction.zip
  inflating: blueprint.cfg
```

Error: missing imported file (Erreur : fichier importé manquant)

AWS Glue renvoie l'erreur « Erreur inconnue lors de l'exécution de la fonction de génération de mise en page FileNotFoundException : [Errno 2] Aucun fichier ou répertoire de ce type : * '*'demo-project/foo.py' ».

Si votre script de génération de mise en page a une fonctionnalité pour lire d'autres fichiers, assurez-vous de donner un chemin complet pour le fichier à importer. Par exemple, le script Conversion.py peut être référencé dans Layout.py. Pour en savoir plus, veuillez consulter la rubrique [Exemple de projet de plan](#).

Erreur : exécution non autorisée iamPassRole sur la ressource

AWS Glue renvoie l'erreur « User : arn:aws:sts : :123456789012:assumed- » role/
AWSGlueServiceRole/GlueSession is not authorized to perform: iam:PassRole on resource:
arn:aws:iam::123456789012:role/AWSGlueServiceRole

Si les travaux et les crawlers du flux de travail assument le même rôle que le rôle transmis pour créer le flux de travail à partir du modèle, alors le rôle du modèle doit inclure l'autorisation `iam:PassRole` pour lui-même.

Si les travaux et les crawlers du flux de travail assument un rôle autre que celui transmis pour créer les entités du flux de travail à partir du modèle, le rôle de ce dernier doit inclure l'autorisation `iam:PassRole` sur cet autre rôle plutôt que sur le rôle du modèle.

Pour plus d'informations, veuillez consulter [Autorisations pour les rôles de plans](#).

Error: invalid cron schedule (Erreur : calendrier cron non valide)

AWS Glue renvoie l'erreur « Le calendrier cron (0 0 * * *) n'est pas valide. »

Fournissez une expression [cron](#) valide. Pour plus d'informations, consultez [Planifications temporelles pour les tâches et les crawlers](#).

Error: a trigger with the same name already exists (Erreur : un déclencheur du même nom existe déjà)

AWS Glue renvoie l'erreur « Le déclencheur portant le nom 'foo_starting_trigger' a déjà été soumis avec une configuration différente ».

Un modèle ne nécessite pas que vous définissiez des déclencheurs dans le script de mise en page pour la création de flux de travail. La création de déclencheur est gérée par la bibliothèque de modèles en fonction des dépendances définies entre deux actions.

La dénomination des déclencheurs est la suivante :

- Pour le déclencheur de démarrage dans le flux de travail, le nom est `<workflow_name>_starting_trigger`.
- Pour un nœud (job/crawler) du flux de travail qui dépend de l'achèvement d'un ou de plusieurs nœuds en amont ; AWS Glue définit un déclencheur nommé `<workflow_name>_<node_name>_trigger`

Cette erreur signifie qu'un déclencheur du même nom existe déjà. Vous pouvez supprimer le déclencheur existant et relancer la création du flux de travail.

Note

La suppression d'un flux de travail ne supprime pas les nœuds du flux de travail. Bien que le flux de travail soit supprimé, il est possible que des déclencheurs soient laissés pour compte. Pour cette raison, vous ne pouvez pas recevoir une erreur « workflow already exists » (le flux de travail existe déjà), mais vous pouvez recevoir une erreur « trigger already exists » (le déclencheur existe déjà) dans le cas où vous créez un flux de travail, le supprimez, puis essayez de le recréer avec le même nom du même modèle.

Erreur : un flux de travail du même nom : foo existe déjà.

Le nom du flux de travail doit être unique. Veuillez essayer avec un nom différent.

Error: module not found in specified layoutGenerator path (Erreur : module introuvable dans le chemin LayoutGenerator spécifié)

AWS Glue renvoie l'erreur « Erreur inconnue lors de l'exécution de la fonction de génération de mise en page ModuleNotFoundError : aucun module nommé 'crawl_s3_locations' ».

```
layoutGenerator": "crawl_s3_locations.layout.generate_layout"
```

Par exemple, si vous avez le chemin layoutGenerator ci-dessus, lorsque vous décompressez l'archive de modèle, il doit ressembler à ce qui suit :

```
$ unzip crawl_s3_locations.zip
Archive:  crawl_s3_locations.zip
  creating: crawl_s3_locations/
  inflating: crawl_s3_locations/blueprint.cfg
  inflating: crawl_s3_locations/layout.py
  inflating: crawl_s3_locations/README.md
```

Lorsque vous décompressez l'archive, si l'archive du modèle ressemble à ce qui suit, vous pouvez obtenir l'erreur ci-dessus.

```
$ unzip crawl_s3_locations.zip
Archive:  crawl_s3_locations.zip
  inflating: blueprint.cfg
  inflating: layout.py
  inflating: README.md
```

Vous pouvez voir qu'il n'y a pas de dossier nommé crawl_s3_locations et lorsque le chemin layoutGenerator fait référence au fichier de mise en page via le module crawl_s3_locations, vous pouvez obtenir l'erreur ci-dessus.

Error: validation error in Connections field (Erreur : erreur de validation dans le champ Connections [Connexions])

AWS Glue renvoie l'erreur « Erreur inconnue lors de l'exécution de la fonction de génération de mise en page TypeError : la valeur ['foo'] pour les connexions clés doit être de type <class 'dict'> ! ».

Il s'agit d'une erreur de validation. Le champs Connections dans le champ Job attend un dictionnaire et à la place une liste de valeurs sont fournies, ce qui provoque l'erreur.

```
User input was list of values
Connections= ['string']

Should be a dict like the following
Connections*={'Connections': ['string']}
```

Pour éviter ces erreurs d'exécution lors de la création d'un flux de travail à partir d'un plan, vous pouvez valider les définitions du flux de travail, de la tâche et du crawler comme indiqué dans [Tester un plan](#).

Reportez-vous à la syntaxe dans [AWS Glue Référence des classes de blueprint](#) pour définir le AWS Glue job, crawler et workflow dans le script de mise en page.

Autorisations pour les personas et les rôles pour AWS Glue plans

Vous trouverez ci-dessous les personas typiques et les politiques d'autorisations suggérées AWS Identity and Access Management (IAM) pour les personas et les rôles pour AWS Glue plans.

Rubriques

- [Personas du plan](#)
- [Autorisations pour les personas du plan](#)
- [Autorisations des rôles de plans](#)

Personas du plan

Voici les personnes généralement impliquées dans le cycle de vie de AWS Glue plans.

Persona	Description
AWS Glue développeur	Développe, teste et publie des modèles.
AWS Glue administrateur	Inscrit, gère et accorde des autorisations pour les modèles.
Analyste des données	Exécute des modèles pour créer des flux de travail.

Pour de plus amples informations, veuillez consulter [the section called “Présentation des plans”](#).

Autorisations pour les personas du plan

Voici les autorisations suggérées pour chaque persona du modèle.

AWS Glue autorisations de développeur pour les plans

Le AWS Glue le développeur doit disposer d'autorisations d'écriture sur le compartiment Amazon S3 utilisé pour publier le plan. Souvent, le développeur enregistre le modèle après l'avoir téléchargé. Dans ce cas, le développeur a besoin des autorisations répertoriées dans [the section called “AWS Glue autorisations d'administrateur pour les plans”](#). De plus, si le développeur souhaite tester le modèle après son enregistrement, il a également besoin des autorisations répertoriées dans [the section called “Autorisations d'analyste des données pour les plans”](#).

AWS Glue autorisations d'administrateur pour les plans

La politique suivante accorde des autorisations d'enregistrement, de consultation et de maintenance AWS Glue plans.

Important

Dans la politique suivante, remplacez *<s3-bucket-name>* et *<prefix>* par le chemin Amazon S3 vers les archives ZIP du plan chargées pour vous enregistrer.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:CreateBlueprint",
        "glue:UpdateBlueprint",
        "glue>DeleteBlueprint",
        "glue:GetBlueprint",
        "glue:ListBlueprints",
        "glue:BatchGetBlueprints"
      ],
      "Resource": "*"
    },
    {
      "Effect": "Allow",
```

```

    "Action": [
        "s3:GetObject"
    ],
    "Resource": "arn:aws:s3:::<s3-bucket-name>/<prefix>/*"
}
]
}

```

Autorisations d'analyste des données pour les plans

La politique suivante accorde des autorisations pour exécuter les modèles et afficher le flux de travail et ses composants résultants. Il accorde également une PassRole importance au rôle qui AWS Glue suppose de créer le flux de travail et les composants du flux de travail.

La politique accorde des autorisations pour n'importe quelle ressource. Si vous souhaitez configurer un accès détaillé à des plans individuels, utilisez le format suivant pour le plan : ARNs

```
arn:aws:glue:<region>:<account-id>:blueprint/<blueprint-name>
```

Important

Dans la politique suivante, remplacez *<account-id>* par un AWS compte valide et remplacez *<role-name>* par le nom du rôle utilisé pour exécuter un plan. Veuillez consulter [the section called “Autorisations des rôles de plans”](#) pour connaître les autorisations requises par ce rôle.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListBlueprints",
        "glue:GetBlueprint",
        "glue:StartBlueprintRun",
        "glue:GetBlueprintRun",
        "glue:GetBlueprintRuns",
        "glue:GetCrawler",
        "glue:ListTriggers",
        "glue:ListJobs",

```



```

        "glue:BatchGetCrawlers",
        "glue:GetTrigger",
        "glue:BatchGetWorkflows",
        "glue:BatchGetTriggers",
        "glue:BatchGetJobs",
        "glue:BatchGetBlueprints",
        "glue:GetWorkflowRun",
        "glue:GetWorkflowRuns",
        "glue:ListCrawlers",
        "glue:ListWorkflows",
        "glue:GetJob",
        "glue:GetWorkflow",
        "glue:StartWorkflowRun"
    ],
    "Resource": "*"
  },
  {
    "Effect": "Allow",
    "Action": "iam:PassRole",
    "Resource": "arn:aws:iam::<account-id>:role/<role-name>"
  }
]
}

```

Autorisations des rôles de plans

Voici les autorisations suggérées pour le rôle IAM utilisé pour créer un flux de travail à partir d'un modèle. Le rôle doit avoir une relation d'approbation avec `glue.amazonaws.com`.

Important

Dans la politique suivante, remplacez `<account-id>` par un AWS compte valide et remplacez `<role-name>` par le nom du rôle.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:CreateJob",

```

```

        "glue:GetCrawler",
        "glue:GetTrigger",
        "glue:DeleteCrawler",
        "glue:CreateTrigger",
        "glue:DeleteTrigger",
        "glue:DeleteJob",
        "glue:CreateWorkflow",
        "glue:DeleteWorkflow",
        "glue:GetJob",
        "glue:GetWorkflow",
        "glue:CreateCrawler"
    ],
    "Resource": "*"
  },
  {
    "Effect": "Allow",
    "Action": "iam:PassRole",
    "Resource": "arn:aws:iam::<account-id>:role/<role-name>"
  }
]
}

```

Note

Si les tâches et les crawlers du flux de travail endossent un rôle autre que celui-ci, cette politique doit inclure l'autorisation `iam:PassRole` pour cet autre rôle plutôt que pour le rôle du modèle.

Élaboration de plans dans AWS Glue

Votre organisation peut avoir un jeu de cas d'utilisation ETL similaires qui pourraient bénéficier de la capacité de paramétrage d'un flux de travail unique pour les gérer tous. Pour répondre à ce besoin, AWS Glue vous permet de définir des plans que vous pouvez utiliser pour générer des flux de travail. Un modèle accepte des paramètres, de sorte qu'à partir d'un modèle unique, un analyste de données peut créer différents flux de travail pour gérer des cas d'utilisation ETL similaires. Après avoir créé un modèle, vous pouvez le réutiliser pour différents services, équipes et projets.

Rubriques

- [Vue d'ensemble des plans dans AWS Glue](#)

- [Élaboration de plans dans AWS Glue](#)
- [Enregistrer un plan dans AWS Glue](#)
- [Visualisation des plans dans AWS Glue](#)
- [Mettre à jour un plan dans AWS Glue](#)
- [Création d'un flux de travail à partir d'un plan dans AWS Glue](#)
- [La visualisation du plan fonctionne dans AWS Glue](#)

Vue d'ensemble des plans dans AWS Glue

Note

La fonctionnalité Blueprints n'est actuellement pas disponible dans les régions suivantes de la console AWS Glue : Asie-Pacifique (Jakarta) et Moyen-Orient (Émirats arabes unis).

AWS Glue les plans offrent un moyen de créer et de partager AWS Glue flux de travail. Lorsqu'un processus ETL complexe pourrait être utilisé pour des cas d'utilisation similaires, plutôt que de créer un AWS Glue flux de travail pour chaque cas d'utilisation, vous pouvez créer un plan unique.

Le modèle spécifie les tâches et les crawlers à inclure dans un flux de travail, et spécifie les paramètres que l'utilisateur du flux de travail fournit lorsqu'il exécute le modèle pour créer un flux de travail. L'utilisation de paramètres permet à un seul modèle de générer des flux de travail pour les différents cas d'utilisation similaires. Pour de plus amples informations sur les flux de travail, veuillez consulter [Vue d'ensemble des flux de travail dans AWS Glue](#).

Voici quelques exemples de cas d'utilisation pour les modèles :

- Vous souhaitez partitionner un jeu de données existant. Les paramètres d'entrée du modèle sont Amazon Simple Storage Service (Amazon S3) et une liste pour les colonnes de partition.
- Vous souhaitez créer un instantané d'une table Amazon DynamoDB dans un magasin de données SQL comme Amazon Redshift. Les paramètres d'entrée du plan sont le nom de la table DynamoDB et un AWS Glue connexion, qui désigne un cluster Amazon Redshift et une base de données de destination.
- Vous souhaitez convertir les données CSV dans plusieurs chemins Amazon S3 en Parquet. Tu veux le AWS Glue flux de travail pour inclure un robot d'exploration et une tâche distincts pour chaque chemin. Les paramètres d'entrée sont la base de données de destination dans le AWS

Glue Catalogue de données et liste de chemins Amazon S3 séparés par des virgules. Notez que dans ce cas, le nombre d'crawlers et de tâches créés par le flux de travail est variable.

Composants du plan

Un modèle est une archive ZIP qui contient les composants suivants :

- Un script de générateur de mise en page Python

Contient une fonction qui spécifie la disposition du flux de travail : les crawlers et les tâches à créer pour le flux de travail, les propriétés de la tâche et de l'crawler et les dépendances entre les tâches et les crawlers. La fonction accepte les paramètres du plan et renvoie une structure de flux de travail (objet JSON) qui AWS Glue utilise pour générer le flux de travail. Étant donné que vous utilisez un script Python pour générer le flux de travail, vous pouvez ajouter votre propre logique adaptée à vos cas d'utilisation.

- Un fichier de configuration

Spécifie le nom complet de la fonction Python qui génère la disposition du flux de travail. Spécifie également les noms, types de données et autres propriétés de tous les paramètres de modèle utilisés par le script.

- (Facultatif) scripts ETL et fichiers de support

En tant que cas d'utilisation avancé, vous pouvez paramétrer l'emplacement des scripts ETL que vos tâches utilisent. Vous pouvez inclure des fichiers de script de tâche dans l'archive ZIP et spécifier un paramètre de modèle pour un emplacement Amazon S3 vers lequel les scripts doivent être copiés. Le script du générateur de mise en page peut copier les scripts ETL à l'emplacement désigné et spécifier cet emplacement en tant que propriété d'emplacement du script de tâche. Vous pouvez également inclure des bibliothèques ou d'autres fichiers de support, à condition que votre script les gère.

Blueprint

Python Script

```
import sys
import os
import json
def generate_layout(use
    etl_job = Job(Name="
```


Config File

```
"layoutGenerator": "My
"parameterSpec" : {
  "WorkflowName" : {
    "type": "String"
    "collection": false
```

Exécutions de modèle

Lorsque vous créez un flux de travail à partir d'un plan, AWS Glue exécute le plan, qui lance un processus asynchrone pour créer le flux de travail ainsi que les tâches, les robots d'exploration et les déclencheurs que le flux de travail encapsule. AWS Glue utilise le plan exécuté pour orchestrer la création du flux de travail et de ses composants. Vous affichez le statut du processus de création en affichant le statut d'exécution du modèle. L'exécution du modèle stocke également les valeurs que vous avez fournies pour les paramètres du modèle.

Blueprint Run



Workflow

Name: MyWF
Role: CreateBP
Sources: 20

Parameter Values

Vous pouvez consulter les plans à l'aide du AWS Glue console ou AWS Command Line Interface (AWS CLI). Lors de l'affichage ou du dépannage d'un flux de travail, vous pouvez toujours revenir à l'exécution du modèle pour afficher les valeurs des paramètres de modèle qui ont été utilisées pour créer le flux de travail.

Cycle de vie d'un plan

les plans sont développés, testés, enregistrés auprès de AWS Glue, et exécutez-le pour créer des flux de travail. Il existe généralement trois personas impliquées dans le cycle de vie du modèle.

Persona	Tâches
AWS Glue développeur	• Écrit le script de mise en page du flux de travail et crée le fichier de configuration. • Teste le plan localement à l'aide des bibliothèques fournies par le AWS Glue service. • Crée une archive ZIP du script, du fichier de configuration et des fichiers de prise en charge et publie l'archive dans un emplacement dans Amazon S3. • Ajoute une politique de compartiment au compartiment Amazon S3 qui accorde des autorisations de lecture sur les objets du compartiment au AWS Glue AWS compte administrateur. • Accorde des autorisations de lecture IAM sur l'archive ZIP d'Amazon S3 au AWS Glue administrateur.
AWS Glue administrateur	• Enregistre le plan auprès de AWS Glue. AWS Glue crée une copie de l'archive ZIP dans un emplacement Amazon S3 réservé. • Accorde des autorisations IAM sur le modèle aux analystes de données.
Analyste des données	• Exécute le modèle pour créer un flux de travail et fournit des valeurs de paramètres de modèle. Vérifie l'état d'exécution du modèle pour s'assurer que le flux de travail et les composants de flux de travail ont été générés avec succès. • Exécute le flux de travail et en résout les problèmes . Avant d'exécuter le flux de travail, vous pouvez vérifier le flux de travail en consultant le graphique de conception du flux de travail sur le AWS Glue console.

 Consultez aussi

- [Élaboration de plans dans AWS Glue](#)

- [Création d'un flux de travail à partir d'un plan dans AWS Glue](#)
- [Autorisations pour les personas et les rôles pour AWS Glue plans](#)

Élaboration de plans dans AWS Glue

En tant que AWS Glue développeur, vous pouvez créer et publier des plans que les analystes de données peuvent utiliser pour générer des flux de travail.

Rubriques

- [Présentation de l'élaboration de plans](#)
- [Prérequis pour l'élaboration des plans](#)
- [Rédiger le code du plan](#)
- [Exemple de projet de plan](#)
- [Test d'un plan](#)
- [Publication d'un plan](#)
- [AWS Glue référence des classes de Blueprint](#)
- [Exemples de plans](#)

Consultez aussi

- [Vue d'ensemble des plans dans AWS Glue](#)

Présentation de l'élaboration de plans

La première étape de votre processus de développement consiste à identifier un cas d'utilisation commun pour lequel un modèle serait utile. Un cas d'utilisation typique implique un problème ETL récurrent qui, selon vous, devrait être résolu de manière générale. Ensuite, concevez un modèle qui implémente le cas d'utilisation généralisé et définissez les paramètres d'entrée du modèle qui ensemble, peuvent définir un cas d'utilisation spécifique à partir du cas d'utilisation généralisé.

Un modèle se compose d'un projet, qui contient un fichier de configuration de paramètres du modèle, de même qu'un script qui définit la structure du flux de travail à générer. La structure définit les tâches et les crawlers (ou entités dans la terminologie du script de modèle) à créer.

Vous ne spécifiez pas directement de déclencheurs dans le script de structure. Au lieu de cela, vous écrivez du code pour spécifier les dépendances entre les tâches et les robots d'exploration créés par le script. AWS Glue génère les déclencheurs en fonction de vos spécifications de dépendance. La sortie du script de structure est un objet de flux de travail, qui contient des spécifications pour toutes les entités de flux de travail.

Vous créez votre objet de flux de travail en utilisant les éléments suivants AWS Glue bibliothèques de plans :

- `awsglue.blueprint.base_resource` - Bibliothèque de ressources de base utilisées par les bibliothèques.
- `awsglue.blueprint.workflow` - Bibliothèque permettant de définir une classe `Workflow`.
- `awsglue.blueprint.job` - Bibliothèque permettant de définir une classe `Job`.
- `awsglue.blueprint.crawler` - Bibliothèque permettant de définir une classe `Crawler`.

Les seules autres bibliothèques qui sont prises en charge pour la génération de structure sont les bibliothèques qui sont disponibles pour le shell Python.

Avant de publier votre modèle, vous pouvez utiliser les méthodes définies dans les bibliothèques de modèles pour le tester localement.

Lorsque vous êtes prêt à mettre le modèle à la disposition des analystes de données, packagez le script, le fichier de configuration des paramètres et tous les fichiers de support, tels que les scripts et les bibliothèques supplémentaires, en une seule ressource déployable. Vous chargez ensuite l'actif sur Amazon S3 et demandez à un administrateur de l'enregistrer auprès AWS Glue.

Pour plus d'informations sur d'autres projets de modèle, veuillez consulter les rubriques [Exemple de projet de plan](#) et [Exemples de plans](#).

Prérequis pour l'élaboration des plans

Pour développer des plans, vous devez être familiarisé avec l'utilisation de AWS Glue et l'écriture de scripts pour les tâches ETL Apache Spark ou les tâches shell Python. Vous devez également effectuer les tâches de configuration suivantes.

- Téléchargez quatre bibliothèques AWS Python à utiliser dans vos scripts de mise en page de plan.
- Configurez le AWS SDKs.
- Configurez le AWS CLI.

Télécharger les bibliothèques Python

Téléchargez les bibliothèques suivantes depuis GitHub et installez-les dans votre projet :

- https://github.com/awslabs/aws-glue-blueprint-libs/tree/master/awsglue/blueprint/base_resource.py
- <https://github.com/awslabs/aws-glue-blueprint-libs/tree/master/awsglue/blueprint/workflow.py>
- <https://github.com/awslabs/aws-glue-blueprint-libs/tree/master/awsglue/blueprint/crawler.py>
- <https://github.com/awslabs/aws-glue-blueprint-libs/tree/master/awsglue/blueprint/job.py>

Configuration du SDK AWS Java

Pour le SDK AWS Java, vous devez ajouter un `jar` fichier qui inclut l'API pour les plans.

1. Si ce n'est pas déjà fait, configurez le AWS SDK pour Java.
 - Pour Java 1.x, suivez les instructions de la rubrique [Configuration de AWS SDK pour Java](#) dans le Guide du développeur AWS SDK pour Java .
 - Pour Java 2.x, suivez les instructions de la rubrique [Configuration de AWS SDK for Java 2.x](#) dans le Guide du développeur AWS SDK for Java 2.x .
2. Téléchargez le `jar` fichier client qui a accès aux plans APIs pour les plans.
 - Pour Java 1.x : `s3://awsglue-custom-blueprints-preview-artifacts/awsglue-java-sdk-preview/AWSGlueJavaClient-1.11.x.jar`
 - Pour Java 2.x : `s3://awsglue-custom-blueprints-preview-artifacts/awsglue-java-sdk-v2-preview/AwsJavaSdk-Glue-2.0.jar`
3. Ajoutez le client `jar` au début du chemin de classe Java pour remplacer le client AWS Glue fourni par le AWS SDK Java.

```
export CLASSPATH=<path-to-preview-client-jar>:$CLASSPATH
```

4. (Facultatif) Testez le SDK avec l'application Java suivante. L'application doit afficher une liste vide.

Remplacez `accessKey` et `secretKey` par vos informations d'identification et remplacez `us-east-1` par votre région.

```
import com.amazonaws.auth.AWSCredentials;  
import com.amazonaws.auth.AWSCredentialsProvider;
```

```
import com.amazonaws.auth.AWSStaticCredentialsProvider;
import com.amazonaws.auth.BasicAWSCredentials;
import com.amazonaws.services.glue.AWSGlue;
import com.amazonaws.services.glue.AWSGlueClientBuilder;
import com.amazonaws.services.glue.model.ListBlueprintsRequest;

public class App{
    public static void main(String[] args) {
        AWSCredentials credentials = new BasicAWSCredentials("accessKey",
"secretKey");
        AWSStaticCredentialsProvider provider = new
AWSStaticCredentialsProvider(credentials);
        AWSGlue glue = AWSGlueClientBuilder.standard().withCredentials(provider)
.withRegion("us-east-1").build();
        ListBlueprintsRequest request = new
ListBlueprintsRequest().withMaxResults(2);
        System.out.println(glue.listBlueprints(request));
    }
}
```

Configuration du SDK AWS Python

Les étapes suivantes supposent que la version 2.7 ou ultérieure de Python, ou la version 3.9 ou ultérieure, est installée sur votre ordinateur.

1. Téléchargez le fichier Wheel boto3 suivant. Si vous êtes invité à ouvrir ou à enregistrer, enregistrez le fichier. `s3 ://awsglue-custom-blueprints-preview- artifacts/aws-python-sdk-preview/ boto 3-1.17.31-py2.py3-none-any.whl`
2. Téléchargez le fichier botocore wheel suivant : `s3 ://awsglue-custom-blueprints-preview- -1.20.31-py2.py3-none-any.whl artifacts/aws-python-sdk-preview/botocore`
3. Vérifiez votre version Python.

```
python --version
```

4. Selon votre version Python, saisissez les commandes suivantes (pour Linux) :
 - Pour Python 2.7 ou supérieur.

```
python3 -m pip install --user virtualenv
source env/bin/activate
```

- Pour Python 3.9 ou version ultérieure.

```
python3 -m venv python-sdk-test
source python-sdk-test/bin/activate
```

5. Installez le fichier Wheel botocore.

```
python3 -m pip install <download-directory>/botocore-1.20.31-py2.py3-none-any.whl
```

6. Installez le fichier Wheel boto3.

```
python3 -m pip install <download-directory>/boto3-1.17.31-py2.py3-none-any.whl
```

7. Configurez vos informations d'identification et région par défaut dans les fichiers `~/.aws/credentials` et `~/.aws/config` suivants. Pour plus d'informations, veuillez consulter la rubrique [Configuration de l' AWS CLI](#) dans le Guide de l'utilisateur de l'AWS Command Line Interface .
8. Testez votre configuration (facultatif). Les commandes suivantes doivent renvoyer une liste vide.

Remplacez `us-east-1` par votre région.

```
$ python
>>> import boto3
>>> glue = boto3.client('glue', 'us-east-1')
>>> glue.list_blueprints()
```

Configuration de l'aperçu AWS CLI

1. Si ce n'est pas déjà fait, installez et/ou mettez à jour le AWS Command Line Interface (AWS CLI) sur votre ordinateur. La façon la plus simple de procéder est d'utiliser `pip`, l'utilitaire d'installation de Python :

```
pip install awscli --upgrade --user
```

Vous pouvez trouver des instructions d'installation complètes pour l'installation de AWS CLI ici : [Installation de AWS Command Line Interface](#).

2. Téléchargez le fichier de AWS CLI roue depuis : `s3://awsglue-custom-blueprints-preview-artifacts/awscli-preview-build/awscli-1.19.31-py2.py3-none-any.whl`

3. Installez le fichier AWS CLI Wheel.

```
python3 -m pip install awscli-1.19.31-py2.py3-none-any.whl
```

4. Exécutez la commande `aws configure`. Configurez vos AWS informations d'identification (y compris la clé d'accès et la clé secrète) et votre AWS région. Vous trouverez des informations sur la configuration du AWS CLI ici : [Configuration du AWS CLI](#).

5. Testez le AWS CLI. La commande suivante doit renvoyer une liste vide.

Remplacez `us-east-1` par votre région.

```
aws glue list-blueprints --region us-east-1
```

Rédiger le code du plan

Chaque projet de modèle que vous créez doit contenir au minimum les fichiers suivants :

- Un script de structure Python qui définit le flux de travail. Le script contient une fonction qui définit les entités (tâches et crawlers) dans un flux de travail, ainsi que les dépendances entre elles.
- Fichier de configuration `blueprint.cfg`, qui définit :
 - Le chemin d'accès complet de la fonction de définition de structure du flux de travail.
 - Les paramètres acceptés par le modèle.

Rubriques

- [Création du script de structure du plan](#)
- [Créez le fichier de configuration](#)
- [Spécifier les paramètres du plan](#)

Création du script de structure du plan

Le script de structure de modèle doit inclure une fonction qui génère les entités dans votre flux de travail. Vous pouvez donner à cette fonction le nom que vous voulez. AWS Glue utilise le fichier de configuration pour déterminer le nom complet de la fonction.

Votre fonction de structure effectue les opérations suivantes :

- (Facultatif) Instancie la classe `Job` pour créer des objets `Job`, et passe des arguments tels que `Command` et `Role`. Il s'agit des propriétés de la tâche que vous devez spécifier si vous créez la tâche à l'aide du AWS Glue console ou API.
- (Facultatif) Instancie la classe `Crawler` pour créer des objets `Crawler`, et passe les arguments `nom`, `rôle` et `cible`.
- Pour indiquer les dépendances entre les objets (entités de flux de travail), transmet les arguments supplémentaires `DependsOn` et `WaitForDependencies` à `Job()` et `Crawler()`. Ces arguments sont expliqués plus loin dans cette section.
- Instancie la `Workflow` classe pour créer l'objet de flux de travail renvoyé à AWS Glue, en passant un `Name` argument, un `Entities` argument et un `OnSchedule` argument facultatif. L'argument `Entities` spécifie tous les tâches et les crawlers à inclure dans le flux de travail. Pour voir comment construire un objet `Entities`, vous trouverez l'exemple de projet plus loin dans cette section.
- Renvoie un objet `Workflow`.

Pour les définitions de classes `Job`, `Crawler` et `Workflow`, veuillez consulter [AWS Glue référence des classes de Blueprint](#).

La fonction de structure doit accepter les arguments d'entrée suivants.

Argument	Description
<code>user_params</code>	Dictionnaire Python des noms et valeurs de paramètres de modèle. Pour de plus amples informations, veuillez consulter Spécifier les paramètres du plan .
<code>system_params</code>	Dictionnaire Python contenant deux propriétés : <code>region</code> et <code>accountId</code> .

Voici un exemple de script générateur de structure dans un fichier nommé `Layout.py` :

```
import argparse
import sys
import os
import json
from awsglue.blueprint.workflow import *
from awsglue.blueprint.job import *
```

```

from awsglue.blueprint.crawler import *

def generate_layout(user_params, system_params):

    etl_job = Job(Name="{}_etl_job".format(user_params['WorkflowName']),
                  Command={
                      "Name": "glueetl",
                      "ScriptLocation": user_params['ScriptLocation'],
                      "PythonVersion": "2"
                  },
                  Role=user_params['PassRole'])
    post_process_job = Job(Name="{}_post_process".format(user_params['WorkflowName']),
                           Command={
                               "Name": "pythonshell",
                               "ScriptLocation": user_params['ScriptLocation'],
                               "PythonVersion": "2"
                           },
                           Role=user_params['PassRole'],
                           DependsOn={
                               etl_job: "SUCCEEDED"
                           },
                           WaitForDependencies="AND")
    sample_workflow = Workflow(Name=user_params['WorkflowName'],
                               Entities=Entities(Jobs=[etl_job, post_process_job]))
    return sample_workflow

```

L'exemple de script importe les bibliothèques de modèles requises et inclut une fonction `generate_layout` qui génère un flux de travail avec deux tâches. Ceci est un script très simple. Un script plus complexe pourrait utiliser une logique et des paramètres supplémentaires pour générer un flux de travail avec de nombreux crawlers et tâches, ou même un nombre variable de tâches et d'crawlers.

Utilisation de l' `DependsOn` argument

L'argument `DependsOn` est une représentation sous forme de dictionnaire d'une dépendance que cette entité a sur d'autres entités dans le flux de travail. Elle se présente sous la forme suivante.

```
DependsOn = {dependency1 : state, dependency2 : state, ...}
```

Les clés de ce dictionnaire représentent la référence à l'objet, et non le nom, de l'entité, tandis que les valeurs sont des chaînes correspondant à l'état à surveiller. AWS Glue déduit les déclencheurs

appropriés. Pour connaître les états valides, veuillez consulter [Condition Structure \(Structure des conditions\)](#).

Par exemple, une tâche peut dépendre de la réussite d'un crawler. Si vous définissez un objet crawler nommé `crawler2` comme suit :

```
crawler2 = Crawler(Name="my_crawler", ...)
```

Ensuite, un objet dépendant de `crawler2` comprendrait un argument de constructeur tel que :

```
DependsOn = {crawler2 : "SUCCEEDED"}
```

Par exemple :

```
job1 = Job(Name="Job1", ..., DependsOn = {crawler2 : "SUCCEEDED", ...})
```

Si `DependsOn` est omis pour une entité, cette entité dépend du déclencheur de démarrage du flux de travail.

Utilisation de l' `WaitForDependencies` argument

L'argument `WaitForDependencies` définit si une entité de tâche ou d'crawler doit attendre jusqu'à ce que toutes les entités dont elle dépend se terminent ou qu'une seule d'entre elles se termine.

Les valeurs autorisées sont « AND » ou « ANY ».

Utilisation de l' `OnSchedule` argument

L'argument `OnSchedule` pour le constructeur de classe `Workflow` est une expression cron qui définit la définition de déclenchement de démarrage d'un flux de travail.

Si cet argument est spécifié, AWS Glue crée un déclencheur de planification avec le calendrier correspondant. Si elle n'est pas spécifiée, le déclencheur de démarrage du flux de travail est un déclencheur à la demande.

Créez le fichier de configuration

Le fichier de configuration de modèle est un fichier obligatoire qui définit le point d'entrée de script pour la génération du flux de travail et les paramètres que le modèle accepte. Le fichier doit être nommé `blueprint.cfg`.

Voici un exemple de fichier de configuration.

```
{
  "layoutGenerator": "DemoBlueprintProject.Layout.generate_layout",
  "parameterSpec" : {
    "WorkflowName" : {
      "type": "String",
      "collection": false
    },
    "WorkerType" : {
      "type": "String",
      "collection": false,
      "allowedValues": ["G1.X", "G2.X"],
      "defaultValue": "G1.X"
    },
    "Dpu" : {
      "type" : "Integer",
      "allowedValues" : [2, 4, 6],
      "defaultValue" : 2
    },
    "DynamoDBTableName": {
      "type": "String",
      "collection" : false
    },
    "ScriptLocation" : {
      "type": "String",
      "collection": false
    }
  }
}
```

La propriété `layoutGenerator` spécifie le nom complet de la fonction dans le script qui génère la structure.

La propriété `parameterSpec` spécifie les paramètres que ce modèle accepte. Pour de plus amples informations, veuillez consulter [Spécifier les paramètres du plan](#).

Important

Votre fichier de configuration doit inclure le nom du flux de travail en tant que paramètre de modèle, ou vous devez générer un nom de flux de travail unique dans votre script de structure.

Spécifier les paramètres du plan

Le fichier de configuration contient les spécifications des paramètres de modèle dans un objet JSON `parameterSpec`. `parameterSpec` contient un ou plusieurs objets paramètres.

```
"parameterSpec": {
  "<parameter_name>": {
    "type": "<parameter-type>",
    "collection": true|false,
    "description": "<parameter-description>",
    "defaultValue": "<default value for the parameter if value not specified>"
    "allowedValues": "<list of allowed values>"
  },
  "<parameter_name>": {
    ...
  }
}
```

Voici les règles de codage de chaque objet paramètre :

- Le nom du paramètre et `type` sont obligatoires. Toutes les autres propriétés sont facultatives.
- Si vous spécifiez la propriété `defaultValue`, le paramètre est facultatif. Sinon, le paramètre est obligatoire et l'analyste de données qui crée un flux de travail à partir du modèle doit lui fournir une valeur.
- Si vous définissez la propriété `collection` à `true`, le paramètre peut prendre une collection de valeurs. Les collections peuvent être de n'importe quel type de données.
- Si vous le spécifiez `allowedValues`, le AWS Glue la console affiche une liste déroulante de valeurs parmi lesquelles l'analyste de données peut choisir lors de la création d'un flux de travail à partir du plan.

Les valeurs suivantes sont autorisées pour `type` :

Types de données de paramètre	Remarques
String	-
Integer	-

Types de données de paramètre	Remarques
Double	-
Boolean	Les valeurs possibles sont true et false. Génère une case à cocher sur la <blueprint>page Créer un flux de travail à partir du AWS Glue console.
S3Uri	Chemin d'accès Amazon S3, en commençant par s3://. Génère un champ de texte et un bouton Browse (Parcourir) sur la page Create a workflow from <blueprint> (Créer un flux de travail à partir du <blueprint>).
S3Bucket	Noms du compartiment Amazon S3 uniquement. Génère un sélecteur de compartiment sur la page Create a workflow from <blueprint> (Créer un flux de travail à partir du <blueprint>).
IAMRoleArn	Nom de ressource Amazon (ARN) d'un rôle AWS Identity and Access Management (IAM). Génère un sélecteur de rôle sur la page Create a workflow from <blueprint> (Créer un flux de travail à partir du <blueprint>).
IAMRoleName	Nom d'un rôle IAM. Génère un sélecteur de rôle sur la page Create a workflow from <blueprint> (Créer un flux de travail à partir du <blueprint>).

Exemple de projet de plan

La conversion de format de données est un cas d'utilisation fréquent d'extraction, de transformation et de chargement (ETL). Dans les charges de travail analytiques typiques, les formats de fichiers basés sur des colonnes comme Parquet ou ORC sont préférés aux formats de texte tels que CSV ou JSON. Cet exemple de plan vous permet de convertir des données CSV/JSON/etc de. en Parquet pour les fichiers sur Amazon S3.

Ce modèle prend une liste de chemins S3 définis par un paramètre de modèle, convertit les données au format Parquet et les écrit à l'emplacement S3 spécifié par un autre paramètre de modèle. Le script de structure crée un crawler et une tâche pour chaque chemin d'accès. Le script de structure

télécharge également le script ETL se trouvant dans `Conversion.py` vers un compartiment S3 spécifié par un autre paramètre de modèle. Le script de structure spécifie ensuite le script téléchargé en tant que script ETL pour chaque tâche. L'archive ZIP du projet contient le script de structure, le script ETL et le fichier de configuration du modèle.

Pour plus d'informations sur d'autres projets de modèle, veuillez consulter la rubrique [Exemples de plans](#).

Ce qui suit est le script de structure, dans le fichier `Layout.py`.

```
from awsglue.blueprint.workflow import *
from awsglue.blueprint.job import *
from awsglue.blueprint.crawler import *
import boto3

s3_client = boto3.client('s3')

# Ingesting all the S3 paths as Glue table in parquet format
def generate_layout(user_params, system_params):
    #Always give the full path for the file
    with open("ConversionBlueprint/Conversion.py", "rb") as f:
        s3_client.upload_fileobj(f, user_params['ScriptsBucket'], "Conversion.py")
    etlScriptLocation = "s3://{}/Conversion.py".format(user_params['ScriptsBucket'])

    crawlers = []
    jobs = []
    workflowName = user_params['WorkflowName']
    for path in user_params['S3Paths']:
        tablePrefix = "source_"
        crawler = Crawler(Name="{}_crawler".format(workflowName),
                          Role=user_params['PassRole'],
                          DatabaseName=user_params['TargetDatabase'],
                          TablePrefix=tablePrefix,
                          Targets= {"S3Targets": [{"Path": path}]})
        crawlers.append(crawler)
    transform_job = Job(Name="{}_transform_job".format(workflowName),
                        Command={"Name": "glueetl",
                                "ScriptLocation": etlScriptLocation,
                                "PythonVersion": "3"},
                        Role=user_params['PassRole'],
                        DefaultArguments={"--database_name":
user_params['TargetDatabase'],
                                       "--table_prefix": tablePrefix,
```

```

                                "--region_name": system_params['region'],
                                "--output_path":
user_params['TargetS3Location']},
                                DependsOn={crawler: "SUCCEEDED"},
                                WaitForDependencies="AND")
    jobs.append(transform_job)
    conversion_workflow = Workflow(Name=workflowName, Entities=Entities(Jobs=jobs,
Crawlers=crawlers))
    return conversion_workflow

```

Ce qui suit est le fichier de configuration du modèle correspondant `blueprint.cfg`.

```

{
  "layoutGenerator": "ConversionBlueprint.Layout.generate_layout",
  "parameterSpec" : {
    "WorkflowName" : {
      "type": "String",
      "collection": false,
      "description": "Name for the workflow."
    },
    "S3Paths" : {
      "type": "S3Uri",
      "collection": true,
      "description": "List of Amazon S3 paths for data ingestion."
    },
    "PassRole" : {
      "type": "IAMRoleName",
      "collection": false,
      "description": "Choose an IAM role to be used in running the job/crawler"
    },
    "TargetDatabase": {
      "type": "String",
      "collection" : false,
      "description": "Choose a database in the Data Catalog."
    },
    "TargetS3Location": {
      "type": "S3Uri",
      "collection" : false,
      "description": "Choose an Amazon S3 output path: ex:s3://<target_path>/."
    },
    "ScriptsBucket": {
      "type": "S3Bucket",
      "collection": false,

```

```

        "description": "Provide an S3 bucket name(in the same AWS Region) to store
the scripts."
    }
}
}

```

Le script suivant dans le fichier `Conversion.py` est le script ETL téléchargé. Notez qu'il conserve le schéma de partitionnement pendant la conversion.

```

import sys
from pyspark.sql.functions import *
from pyspark.context import SparkContext
from awsglue.transforms import *
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions
import boto3

args = getResolvedOptions(sys.argv, [
    'JOB_NAME',
    'region_name',
    'database_name',
    'table_prefix',
    'output_path'])
databaseName = args['database_name']
tablePrefix = args['table_prefix']
outputPath = args['output_path']

glue = boto3.client('glue', region_name=args['region_name'])

glue_context = GlueContext(SparkContext.getOrCreate())
spark = glue_context.spark_session
job = Job(glue_context)
job.init(args['JOB_NAME'], args)

def get_tables(database_name, table_prefix):
    tables = []
    paginator = glue.get_paginator('get_tables')
    for page in paginator.paginate(DatabaseName=database_name, Expression=table_prefix
+"""):
        tables.extend(page['TableList'])
    return tables

```

```
for table in get_tables(databaseName, tablePrefix):
    tableName = table['Name']
    partitionList = table['PartitionKeys']
    partitionKeys = []
    for partition in partitionList:
        partitionKeys.append(partition['Name'])

    # Create DynamicFrame from Catalog
    dyf = glue_context.create_dynamic_frame.from_catalog(
        name_space=databaseName,
        table_name=tableName,
        additional_options={
            'useS3ListImplementation': True
        },
        transformation_ctx='dyf'
    )

    # Resolve choice type with make_struct
    dyf = ResolveChoice.apply(
        frame=dyf,
        choice='make_struct',
        transformation_ctx='resolvechoice_' + tableName
    )

    # Drop null fields
    dyf = DropNullFields.apply(
        frame=dyf,
        transformation_ctx="dropnullfields_" + tableName
    )

    # Write DynamicFrame to S3 in glueparquet
    sink = glue_context.getSink(
        connection_type="s3",
        path=outputPath,
        enableUpdateCatalog=True,
        partitionKeys=partitionKeys
    )
    sink.setFormat("glueparquet")

    sink.setCatalogInfo(
        catalogDatabase=databaseName,
        catalogTableName=tableName[len(tablePrefix):]
    )
    sink.writeFrame(dyf)
```

```
job.commit()
```

Note

Seuls deux chemins Amazon S3 peuvent être fournis en entrée pour l'exemple de modèle. C'est parce que AWS Glue les déclencheurs sont limités à l'invocation de deux actions de crawler uniquement.

Test d'un plan

Pendant que vous développez votre code, vous devez effectuer des tests locaux pour vérifier que la structure du flux de travail est correcte.

Les tests locaux ne génèrent pas AWS Glue jobs, crawlers ou déclencheurs. Au lieu de cela, vous exécutez le script de structure localement et utilisez la méthode `to_json()` et `validate()` pour imprimer des objets et trouver des erreurs. Ces méthodes sont disponibles dans les trois classes définies dans les bibliothèques.

Il existe deux manières de gérer les `system_params` arguments `user_params` et qui AWS Glue passe à votre fonction de mise en page. Votre code de banc de test peut créer un dictionnaire d'exemples de valeurs de paramètre de modèle et le transmettre à la fonction de structure en tant qu'argument `user_params`. Vous pouvez également supprimer les références à `user_params` et remplacez-les par des chaînes codées en dur.

Si votre code utilise les propriétés `region` et `accountId` dans `system_params`, vous pouvez passer votre propre dictionnaire pour `system_params`.

Pour tester un modèle

1. Démarrez un interpréteur Python dans un répertoire avec les bibliothèques, ou chargez les fichiers du modèle et les bibliothèques fournies dans votre environnement de développement intégré (IDE) préféré.
2. Assurez-vous que votre code importe les bibliothèques fournies.
3. Ajouter du code à votre fonction de structure pour appeler `validate()` ou `to_json()` sur n'importe quelle entité ou sur l'objet `Workflow`. Par exemple, si votre code crée un objet `Crawler` nommé `mycrawler`, vous pouvez appeler `validate()` comme suit.

```
mycrawler.validate()
```

Vous pouvez imprimer `mycrawler` comme suit :

```
print(mycrawler.to_json())
```

Si vous appelez `to_json` sur un objet, il n'est pas nécessaire d'appeler également `validate()`, parce que `to_json()` appelle `validate()`.

Il est plus utile d'appeler ces méthodes sur l'objet de flux de travail. En supposant que votre script nomme l'objet de flux de travail `my_workflow`, validez et imprimez l'objet de flux de travail comme suit.

```
print(my_workflow.to_json())
```

Pour plus d'informations sur `to_json()` et `validate()`, consultez [Méthodes de classe](#).

Vous pouvez également importer `pprint` et imprimer l'objet de flux de travail, tel que décrit dans l'exemple plus loin dans cette section.

4. Exécutez le code, corrigez les erreurs et supprimez enfin tous les appels à `validate()` ou `to_json()`.

Exemple

L'exemple suivant montre comment construire un dictionnaire d'exemples de paramètres de modèle et le transmettre en tant qu'argument `user_params` à la fonction de structure `generate_compaction_workflow`. L'exemple montre également comment imprimer automatiquement l'objet de flux de travail généré.

```
from pprint import pprint
from awsglue.blueprint.workflow import *
from awsglue.blueprint.job import *
from awsglue.blueprint.crawler import *

USER_PARAMS = {"WorkflowName": "compaction_workflow",
               "ScriptLocation": "s3://amzn-s3-demo-bucket/scripts/threaded-
compaction.py",
               "PassRole": "arn:aws:iam::111122223333:role/GlueRole-ETL",
```



```

        "DatabaseName": "cloudtrial",
        "TableName": "ct_cloudtrail",
        "CoalesceFactor": 4,
        "MaxThreadWorkers": 200}

def generate_compaction_workflow(user_params: dict, system_params: dict) -> Workflow:
    compaction_job = Job(Name=f"{user_params['WorkflowName']}_etl_job",
        Command={"Name": "glueetl",
            "ScriptLocation": user_params['ScriptLocation'],
            "PythonVersion": "3"},
        Role="arn:aws:iam::111122223333:role/
AWSGlueServiceRoleDefault",
        DefaultArguments={"DatabaseName": user_params['DatabaseName'],
            "TableName": user_params['TableName'],
            "CoalesceFactor":
user_params['CoalesceFactor'],
                        "max_thread_workers":
user_params['MaxThreadWorkers']})

    catalog_target = {"CatalogTargets": [{"DatabaseName": user_params['DatabaseName'],
"Tables": [user_params['TableName']]}]}

    compacted_files_crawler = Crawler(Name=f"{user_params['WorkflowName']}_post_crawl",
        Targets = catalog_target,
        Role=user_params['PassRole'],
        DependsOn={compaction_job: "SUCCEEDED"},
        WaitForDependencies="AND",
        SchemaChangePolicy={"DeleteBehavior": "LOG"})

    compaction_workflow = Workflow(Name=user_params['WorkflowName'],
        Entities=Entities(Jobs=[compaction_job],

Crawlers=[compacted_files_crawler]))
    return compaction_workflow

generated = generate_compaction_workflow(user_params=USER_PARAMS, system_params={})
gen_dict = generated.to_json()

pprint(gen_dict)

```

Publication d'un plan

Une fois que vous avez développé un modèle, vous devez le télécharger vers Amazon S3. Vous devez disposer d'autorisations en écriture sur le compartiment Amazon S3 que vous utilisez pour publier le modèle. Vous devez également vous assurer que AWS Glue l'administrateur, qui enregistrera le plan, dispose d'un accès en lecture au compartiment Amazon S3. Pour les politiques d'autorisation suggérées AWS Identity and Access Management (IAM) pour les personas et les rôles pour AWS Glue des plans, voyez [Autorisations pour les personas et les rôles pour AWS Glue plans](#).

Pour publier un modèle

1. Créez les scripts, les ressources et le fichier de configuration de modèle nécessaires.
2. Ajoutez tous les fichiers à une archive ZIP et téléchargez ce fichier ZIP sur Amazon S3. Utilisez un compartiment S3 qui se trouve dans la même région que celle dans laquelle les utilisateurs vont enregistrer et exécuter le modèle.

Vous pouvez créer un fichier ZIP à partir de la ligne de commande à l'aide de la commande suivante.

```
zip -r folder.zip folder
```

3. Ajoutez une politique de compartiment qui accorde des autorisations de lecture au compte AWS souhaité. Voici un exemple de politique.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "AWS": "arn:aws:iam::111122223333:root"
      },
      "Action": "s3:GetObject",
      "Resource": "arn:aws:s3:::my-blueprints/*"
    }
  ]
}
```

4. Accordez l'`s3:GetObject` autorisation IAM sur le compartiment Amazon S3 à AWS Glue administrateur ou à la personne qui enregistrera les plans. Pour obtenir un exemple de politique

d'octroi d'accès aux administrateurs, veuillez consulter la rubrique [AWS Glue autorisations d'administrateur pour les plans](#).

Une fois que vous avez terminé le test local de votre plan, vous souhaitez peut-être également tester un plan sur AWS Glue. Pour tester un plan sur AWS Glue, il doit être enregistré. Vous pouvez limiter qui voit le modèle enregistré à l'aide de l'autorisation IAM ou à l'aide de comptes de test distincts.

 Voir aussi :

- [Enregistrer un plan dans AWS Glue](#)

AWS Glue référence des classes de Blueprint

Les bibliothèques pour AWS Glue les plans définissent trois classes que vous utilisez dans votre script de mise en page de flux de travail : `JobCrawler`, `etWorkflow`.

Rubriques

- [Classe Tâche](#)
- [Classe de crawler](#)
- [Classe de flux de travail](#)
- [Méthodes de classe](#)

Classe Tâche

La `Job` classe représente un AWS Glue Job ETL.

Arguments de constructeur obligatoires

Les arguments de constructeur suivants sont obligatoires pour la classe `Job`.

Nom d'argument	Type	Description
<code>Name</code>	<code>str</code>	Nom à attribuer à la tâche. AWS Glue ajoute un suffixe généré de manière aléatoire au nom pour

Nom d'argument	Type	Description
		distinguer la tâche de celles créées par d'autres exécutions de plans.
Role	str	Amazon Resource Name (ARN) du rôle que la tâche doit assumer lors de son exécution.
Command	dict	Commande de tâche, comme spécifié dans la rubrique JobCommand structure de la documentation de l'API.

Arguments de constructeur facultatifs

Les arguments de constructeur suivants sont facultatifs pour la classe Job.

Nom d'argument	Type	Description
DependsOn	dict	Liste des entités de flux de travail dont dépend la tâche. Pour de plus amples informations, veuillez consulter Utilisation de l' DependsOn argument .
WaitForDependencies	str	Indique si la tâche doit attendre jusqu'à ce que toutes les entités dont elle dépend se terminent ou qu'une seule d'entre elles se termine avant de s'exécuter. Pour de plus amples informations, veuillez consulter Utilisation de l' WaitForDependencies argument . Omettre si la tâche ne dépend que d'une seule entité.
(Propriétés de la tâche)	-	Toutes les propriétés du poste répertoriées Structure Job dans le AWS Glue Documentation de l'API (sauf CreatedOn et LastModifiedOn).

Classe de crawler

La `Crawler` classe représente un AWS Glue chenille.

Arguments de constructeur obligatoires

Les arguments de constructeur suivants sont obligatoires pour la classe `Crawler`.

Nom d'argument	Type	Description
Name	str	Nom à attribuer au robot d'exploration. AWS Glue ajoute un suffixe généré aléatoirement au nom pour distinguer le crawler de ceux créés par d'autres exécutions de blueprint.
Role	str	ARN du rôle que l'crawler doit assumer lors de l'exécution.
Targets	dict	Collecte de cibles à analyser. Les arguments de constructeur de classe <code>Targets</code> sont définis dans la rubrique CrawlerTargets structure de la documentation de l'API. Tous les arguments de constructeur <code>Targets</code> sont facultatifs, mais vous devez en passer au moins un.

Arguments de constructeur facultatifs

Les arguments de constructeur suivants sont facultatifs pour la classe `Crawler`.

Nom d'argument	Type	Description
DependsOn	dict	Liste des entités de flux de travail dont dépend l'crawler. Pour de plus amples informations, veuillez consulter Utilisation de l' DependsOn argument .
WaitForDependencies	str	Indique si l'crawler doit attendre jusqu'à ce que toutes les entités dont il dépend se terminent ou qu'une seule d'entre elles se termine avant

Nom d'argument	Type	Description
		de s'exécuter. Pour de plus amples informations, veuillez consulter Utilisation de l' WaitForDependencies argument . Omettre si l'crawler ne dépend que d'une seule entité.
(Propriétés de l'crawler)	-	Toutes les propriétés du crawler répertoriées Structure du crawler dans le AWS Glue Documentation de l'API, avec les exceptions suivantes : • State • CrawlElapsedTime • CreationTime • LastUpdated • LastCrawl • Version

Classe de flux de travail

La Workflow classe représente un AWS Glue flux de travail. Le script de mise en page du flux de travail renvoie un Workflow objet. AWS Glue crée un flux de travail basé sur cet objet.

Arguments de constructeur obligatoires

Les arguments de constructeur suivants sont obligatoires pour la classe Workflow.

Nom d'argument	Type	Description
Name	str	Nom à affecter au flux de travail.
Entities	Entities	Ensemble d'entités (tâches et crawlers) à inclure dans le flux de travail. Le constructeur de classe Entities accepte un argument Jobs, qui est une liste de Job et un objet Crawlers, qui est une liste d'objets Crawler.

Arguments de constructeur facultatifs

Les arguments de constructeur suivants sont facultatifs pour la classe `Workflow`.

Nom d'argument	Type	Description
Description	str	Consultez Structure de flux de travail .
DefaultRunProperties	dict	Consultez Structure de flux de travail .
OnSchedule	str	Une expression cron.

Méthodes de classe

Les trois classes comprennent les méthodes suivantes.

`validate()`

Valide les propriétés de l'objet et, si des erreurs sont détectées, affiche un message et sort. Ne génère aucune sortie s'il n'y a pas d'erreurs. Pour la classe `Workflow`, s'appelle elle-même pour chaque entité du flux de travail.

`to_json()`

Séréalise l'objet au format JSON. Appelle également `validate()`. Pour la classe `Workflow`, l'objet JSON inclut des listes de tâches et d'crawlers, ainsi qu'une liste de déclencheurs générés par les spécifications de dépendance de la tâche et de l'crawler.

Exemples de plans

Un certain nombre d'exemples de projets de plan sont disponibles sur le [AWS Glue référentiel Github Blueprint](#). Ces exemples sont à titre de référence seulement et ne sont pas destinés à la production.

Les titres des projets exemples sont :

- Compactage : ce modèle crée une tâche qui compacte les fichiers d'entrée en paquets plus volumineux en fonction de la taille de fichier souhaitée.
- Conversion : ce modèle convertit les fichiers d'entrée dans différents formats de fichiers standard au format Apache Parquet, qui est optimisé pour les charges de travail analytiques.

- **Analyse des emplacements Amazon S3** : ce modèle analyse plusieurs emplacements Amazon S3 pour ajouter des tables de métadonnées au catalogue de données.
- **Connexion personnalisée au catalogue de données** : ce plan permet d'accéder aux magasins de données à l'aide de AWS Glue connecteurs personnalisés, lit les enregistrements et renseigne les définitions des tables dans le catalogue de données AWS Glue en fonction du schéma d'enregistrement.
- **Encodage** : ce modèle convertit vos fichiers non-UTF en fichiers encodés UTF.
- **Partitionnement** : ce modèle crée une tâche de partitionnement qui place les fichiers de sortie dans des partitions basées sur des clés de partition spécifiques.
- **Importation de données Amazon S3 dans une table DynamoDB** : ce modèle importe les données d'Amazon S3 dans une table DynamoDB.
- **Table standard à gouverner** : ce plan importe une table AWS Glue Data Catalog dans une table Lake Formation.

Enregistrer un plan dans AWS Glue

Après le AWS Glue le développeur a codé le plan et téléchargé une archive ZIP sur Amazon Simple Storage Service (Amazon S3), un AWS Glue l'administrateur doit enregistrer le plan. L'enregistrement du modèle le rend disponible pour utilisation.

Lorsque vous enregistrez un plan, AWS Glue copie l'archive du plan dans un emplacement Amazon S3 réservé. Vous pouvez ensuite supprimer l'archive de l'emplacement de téléchargement.

Pour enregistrer un modèle, vous avez besoin d'autorisations de lecture sur l'emplacement Amazon S3 qui contient l'archive téléchargée. Vous avez également besoin de l'autorisation AWS Identity and Access Management `glue:CreateBlueprint` (IAM). Pour les autorisations suggérées pour un AWS Glue administrateur qui doit enregistrer, consulter et gérer les plans, voir [AWS Glue autorisations d'administrateur pour les plans](#).

Vous pouvez enregistrer un plan à l'aide du AWS Glue console, AWS Glue API, ou AWS Command Line Interface (AWS CLI).

Pour enregistrer un modèle (console)

1. Assurez-vous de disposer des autorisations de lecture (`s3:GetObject`) dans l'archive ZIP du modèle dans Amazon S3.
2. Ouvrez le fichier AWS Glue console à <https://console.aws.amazon.com/glue/>.

Connectez-vous sous un profil utilisateur qui dispose des autorisations nécessaires pour enregistrer un modèle. Basculez vers la même région AWS en tant que compartiment Amazon S3 contenant l'archive ZIP du modèle.

3. Dans le panneau de navigation, sélectionnez Plans. Ensuite, sur la page Plans, sélectionnez Ajouter un plan.
4. Saisissez un nom de modèle et, éventuellement, une description.
5. Pour ZIP archive location (S3) (Emplacement de l'archive ZIP [S3]), saisissez le chemin Amazon S3 de l'archive ZIP du modèle téléchargé. Incluez le nom du fichier d'archive dans le chemin d'accès et commencez le chemin par `s3://`.
6. (Facultatif) Ajoutez une balise ou plusieurs balises.
7. Sélectionnez Add blueprint (Ajouter un modèle).

La page Plans renvoie des résultats et indique que le statut du plan est à CREATING. Cliquez sur le bouton d'actualisation jusqu'à ce que le statut devienne ACTIVE ou FAILED.

8. Si le statut est FAILED, sélectionnez le modèle et dans le menu Actions, sélectionnez View (Afficher).

La page des détails indique la raison de l'échec. Si le message d'erreur est « Unable to access object at location... » (Impossible d'accéder à l'objet à l'emplacement...) ou « Access denied on object at location... » (Accès refusé sur l'objet à l'emplacement...), passez en revue les exigences suivantes :

- L'utilisateur sous lequel vous êtes connecté doit disposer d'une autorisation de lecture sur l'archive ZIP du modèle dans Amazon S3.
 - Le compartiment Amazon S3 qui contient l'archive ZIP doit avoir une politique de compartiment qui accorde une autorisation de lecture sur l'objet à votre identifiant de AWS compte. Pour de plus amples informations, veuillez consulter [Élaboration de plans dans AWS Glue](#).
 - Le compartiment Amazon S3 que vous utilisez doit se trouver dans la même région que la région à laquelle vous êtes connecté sur la console.
9. Assurez-vous que les analystes de données disposent d'autorisations sur le modèle.

La politique IAM suggérée pour les analystes des données est illustrée dans [Autorisations d'analyste des données pour les plans](#). Cette politique accorde glue:GetBlueprint pour

n'importe quelle ressource. Si votre politique est plus précise au niveau des ressources, accordez des autorisations aux analystes des données sur cette ressource qui vient d'être créée.

Pour enregistrer un plan (AWS CLI)

1. Entrez la commande suivante.

```
aws glue create-blueprint --name <blueprint-name> [--description <description>] --  
blueprint-location s3://<s3-path>/<archive-filename>
```

2. Pour vérifier l'état du modèle, saisissez la commande suivante. Répétez la commande jusqu'à ce que le statut devienne ACTIVE ou FAILED.

```
aws glue get-blueprint --name <blueprint-name>
```

Si le statut est FAILED et le message d'erreur est « Unable to access object at location... » (Impossible d'accéder à l'objet à l'emplacement...) ou « Access denied on object at location... » (Accès refusé sur l'objet à l'emplacement...), passez en revue les exigences suivantes :

- L'utilisateur sous lequel vous êtes connecté doit disposer d'une autorisation de lecture sur l'archive ZIP du modèle dans Amazon S3.
- Le compartiment Amazon S3 contenant l'archive ZIP doit avoir une politique de compartiment qui accorde une autorisation de lecture sur l'objet à votre identifiant de AWS compte. Pour de plus amples informations, veuillez consulter [Publication d'un plan](#).
- Le compartiment Amazon S3 que vous utilisez doit se trouver dans la même région que la région à laquelle vous êtes connecté sur la console.

 Voir aussi :

- [Vue d'ensemble des plans dans AWS Glue](#)

Visualisation des plans dans AWS Glue

Affichez un modèle pour consulter la description, l'état et les spécifications des paramètres du celui-ci, et pour télécharger son archive ZIP.

Vous pouvez consulter un plan en utilisant le AWS Glue console, AWS Glue API, ou AWS Command Line Interface (AWS CLI).

Pour afficher un modèle (console)

1. Ouvrez le fichier AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sélectionnez Plans.
3. Sur la page plans, sélectionnez un plan. Ensuite, dans le menu Actions, sélectionnez View (Afficher).

Pour afficher un plan (AWS CLI)

- Saisissez la commande suivante pour afficher uniquement le nom, la description et l'état du modèle. Remplacez *<blueprint-name>* par le nom du plan à afficher.

```
aws glue get-blueprint --name <blueprint-name>
```

Le résultat de la commande se présente comme suit.

```
{
  "Blueprint": {
    "Name": "myDemoBP",
    "CreatedOn": 1587414516.92,
    "LastModifiedOn": 1587428838.671,
    "BlueprintLocation": "s3://amzn-s3-demo-bucket1/demo/
DemoBlueprintProject.zip",
    "Status": "ACTIVE"
  }
}
```

Saisissez la commande suivante pour afficher également les spécifications des paramètres.

```
aws glue get-blueprint --name <blueprint-name> --include-parameter-spec
```

Le résultat de la commande se présente comme suit.

```
{
  "Blueprint": {
    "Name": "myDemoBP",
```

```

    "CreatedOn": 1587414516.92,
    "LastModifiedOn": 1587428838.671,
    "ParameterSpec": "{\\\"WorkflowName\\\":{\\\"type\\\":\\\"String\\\",\\\"collection\\\":false,\\\"description\\\":null,\\\"defaultValue\\\":null,\\\"allowedValues\\\":null},\\\"PassRole\\\":{\\\"type\\\":\\\"String\\\",\\\"collection\\\":false,\\\"description\\\":null,\\\"defaultValue\\\":null,\\\"allowedValues\\\":null},\\\"DynamoDBTableName\\\":{\\\"type\\\":\\\"String\\\",\\\"collection\\\":false,\\\"description\\\":null,\\\"defaultValue\\\":null,\\\"allowedValues\\\":null},\\\"ScriptLocation\\\":{\\\"type\\\":\\\"String\\\",\\\"collection\\\":false,\\\"description\\\":null,\\\"defaultValue\\\":null,\\\"allowedValues\\\":null}}\",
    \"BlueprintLocation\": \"s3://awsexamplebucket1/demo/DemoBlueprintProject.zip\",
    \"Status\": \"ACTIVE\"
  }
}

```

Ajoutez l'`--include-blueprint` argument pour inclure une URL dans la sortie que vous pouvez coller dans votre navigateur pour télécharger l'archive ZIP du plan qui AWS Glue stocké.

 Voir aussi :

- [Vue d'ensemble des plans dans AWS Glue](#)

Mettre à jour un plan dans AWS Glue

Vous pouvez mettre à jour un modèle si vous disposez d'un script de mise en page révisé, d'un ensemble révisé de paramètres de modèle ou de fichiers de support révisés. La mise à jour d'un modèle crée une nouvelle version.

La mise à jour d'un modèle n'affecte pas les flux de travail existants créés à partir du modèle.

Vous pouvez mettre à jour un plan à l'aide du AWS Glue console, AWS Glue API, ou AWS Command Line Interface (AWS CLI).

La procédure suivante suppose que AWS Glue le développeur a créé et chargé une archive ZIP de plan mise à jour sur Amazon S3.

Pour mettre à jour un plan (console)

1. Assurez-vous de disposer des autorisations de lecture (`s3:GetObject`) dans l'archive ZIP du modèle dans Amazon S3.
2. Ouvrez le fichier AWS Glue console à <https://console.aws.amazon.com/glue/>.

Connectez-vous sous un profil utilisateur qui dispose des autorisations nécessaires pour mettre à jour un modèle. Basculez vers la même région AWS en tant que compartiment Amazon S3 contenant l'archive ZIP du modèle.

3. Dans le panneau de navigation, sélectionnez Plans.
4. Sur la page plans, sélectionnez un plan, puis dans le menu Actions, sélectionnez Modifier.
5. Dans la page Edit a blueprint (Modifier un modèle), mettez à jour la Description du modèle ou ZIP archive location (S3) (Emplacement de l'archive ZIP [S3]). Veillez à inclure le nom du fichier de l'archive dans le chemin.
6. Choisissez Save (Enregistrer).

La page plans affiche des résultats indiquant que le statut du plan est UPDATING. Cliquez sur le bouton d'actualisation jusqu'à ce que le statut devienne ACTIVE ou FAILED.

7. Si le statut est FAILED, sélectionnez le modèle et dans le menu Actions, sélectionnez View (Afficher).

La page des détails indique la raison de l'échec. Si le message d'erreur est « Unable to access object at location... » (Impossible d'accéder à l'objet à l'emplacement...) ou « Access denied on object at location... » (Accès refusé sur l'objet à l'emplacement...), passez en revue les exigences suivantes :

- L'utilisateur sous lequel vous êtes connecté doit disposer d'une autorisation de lecture sur l'archive ZIP du modèle dans Amazon S3.
- Le compartiment Amazon S3 qui contient l'archive ZIP doit avoir une politique de compartiment qui accorde une autorisation de lecture sur l'objet à votre identifiant de AWS compte. Pour de plus amples informations, veuillez consulter [Publication d'un plan](#).
- Le compartiment Amazon S3 que vous utilisez doit se trouver dans la même région que la région à laquelle vous êtes connecté sur la console.

 Note

Si la mise à jour échoue, la prochaine exécution de modèle utilise la dernière version du modèle qui a été enregistrée ou mise à jour avec succès.

Pour mettre à jour un modèle (AWS CLI)

1. Entrez la commande suivante.

```
aws glue update-blueprint --name <blueprint-name> [--description <description>] --  
blueprint-location s3://<s3-path>/<archive-filename>
```

2. Pour vérifier l'état du modèle, saisissez la commande suivante. Répétez la commande jusqu'à ce que le statut devienne ACTIVE ou FAILED.

```
aws glue get-blueprint --name <blueprint-name>
```

Si le statut est FAILED et le message d'erreur est « Unable to access object at location... » (Impossible d'accéder à l'objet à l'emplacement...) ou « Access denied on object at location... » (Accès refusé sur l'objet à l'emplacement...), passez en revue les exigences suivantes :

- L'utilisateur sous lequel vous êtes connecté doit disposer d'une autorisation de lecture sur l'archive ZIP du modèle dans Amazon S3.
- Le compartiment Amazon S3 contenant l'archive ZIP doit avoir une politique de compartiment qui accorde une autorisation de lecture sur l'objet à votre identifiant de AWS compte. Pour de plus amples informations, veuillez consulter [Publication d'un plan](#).
- Le compartiment Amazon S3 que vous utilisez doit se trouver dans la même région que la région à laquelle vous êtes connecté sur la console.

 Consultez aussi

- [Vue d'ensemble des plans dans AWS Glue](#)

Création d'un flux de travail à partir d'un plan dans AWS Glue

Vous pouvez créer un AWS Glue flux de travail manuellement, en ajoutant un composant à la fois, ou vous pouvez créer un flux de travail à partir d'un AWS Glue [plan](#). AWS Glue inclut des plans pour les cas d'utilisation courants. Votre AWS Glue les développeurs peuvent créer des plans supplémentaires.

Important

Limitez le nombre total de tâches, de crawlers et de déclencheurs au sein d'un flux de travail à 100 ou moins. Si vous en incluez plus de 100, vous risquez de rencontrer des erreurs lorsque vous tentez de reprendre ou d'arrêter les exécutions du flux de travail.

Lorsque vous utilisez un modèle, vous pouvez générer rapidement un flux de travail pour un cas d'utilisation spécifique basé sur le cas d'utilisation généralisé défini par le modèle. Vous définissez le cas d'utilisation spécifique en fournissant des valeurs pour les paramètres de modèle. Par exemple, un modèle qui partitionne un jeu de données peut avoir les chemins source et cible Amazon S3 comme paramètres.

AWS Glue crée un flux de travail à partir d'un plan en exécutant le plan. L'exécution du modèle directeur enregistre les valeurs des paramètres que vous avez fournies et est utilisée pour suivre la progression et le résultat de la création du flux de travail et de ses composants. Lors du dépannage d'un flux de travail, vous pouvez afficher l'exécution du modèle pour déterminer les valeurs des paramètres de modèle qui ont été utilisées pour créer un flux de travail.

Pour créer et afficher des flux de travail, vous avez besoin de certaines autorisations IAM. Pour consulter un exemple de politique IAM, veuillez consulter [Autorisations d'analyste des données pour les plans](#).

Vous pouvez créer un flux de travail à partir d'un plan en utilisant AWS Glue console, AWS Glue API, ou AWS Command Line Interface (AWS CLI).

Pour créer un flux de travail à partir d'un modèle (console)

1. Ouvrez le fichier AWS Glue console à <https://console.aws.amazon.com/glue/>.

Connectez-vous en tant qu'utilisateur disposant des autorisations pour créer un flux de travail.

2. Dans le panneau de navigation, sélectionnez Plans.

3. Sélectionnez un modèle, puis dans le menu Actions, sélectionnez Create workflow (Créer un flux de travail).
4. Dans la page Create a workflow from <blueprint-name> (Créer un flux de travail à partir de <blueprint-name>), saisissez les informations suivantes :

Paramètres des modèles

Ceux-ci varient en fonction de la conception du modèle. Pour toute question concernant les paramètres, veuillez consulter le développeur. Les plans incluent généralement un paramètre pour le nom du flux de travail.

Rôle IAM

Le rôle qui AWS Glue suppose de créer le flux de travail et ses composants. Le rôle doit disposer des autorisations pour créer et supprimer des flux de travail, des tâches, des crawlers et des déclencheurs. Pour obtenir un exemple de politique pour le rôle, veuillez consulter [Autorisations des rôles de plans](#).

5. Sélectionnez Envoyer.

La page Blueprint Details (Détails du modèle) s'affiche et affiche une liste des exécutions de modèle en bas.

6. Dans la liste des exécutions de modèle, vérifiez l'exécution de modèle en tête de liste pour connaître l'état de création du flux de travail.

L'état initial est RUNNING. Cliquez sur le bouton d'actualisation jusqu'à ce que le statut devienne SUCCEEDED ou FAILED.

7. Effectuez l'une des actions suivantes :

- Si le statut d'achèvement est SUCCEEDED, vous pouvez accéder à la page Workflows (Flux de travail), puis sélectionnez le flux de travail qui vient d'être créé et exécutez-le. Avant d'exécuter le flux de travail, vous pouvez consulter le graphique de conception.
- Si le statut d'achèvement est FAILED, sélectionnez l'exécution du modèle, puis dans la fenêtre Actions, sélectionnez View (Afficher) pour afficher le message d'erreur.

Pour en savoir plus sur les flux de travail et les plans, consultez les rubriques suivantes.

- [Vue d'ensemble des flux de travail dans AWS Glue](#)
- [Mettre à jour un plan dans AWS Glue](#)

- [Création et développement manuels d'un flux de travail dans AWS Glue](#)

La visualisation du plan fonctionne dans AWS Glue

Affichez une exécution de modèle pour afficher les informations suivantes :

- Nom du flux de travail qui a été créé.
- Valeurs de paramètre du plan utilisées pour créer le flux de travail.
- Statut de l'opération de création du flux de travail.

Vous pouvez consulter un plan exécuté à l'aide du AWS Glue console, AWS Glue API, ou AWS Command Line Interface (AWS CLI).

Pour afficher une exécution de modèle (console)

1. Ouvrez le fichier AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation, sélectionnez Plans.
3. Sur la page plans, sélectionnez un plan. Ensuite, dans le menu Actions, sélectionnez View (Afficher).
4. Au bas de la page Blueprint Details (Détails des modèles), sélectionnez une exécution de modèle, puis dans le menu Actions, sélectionnez View (Afficher).

Pour afficher une exécution de modèle (AWS CLI)

- Entrez la commande suivante. Remplacez *<blueprint-name>* par le nom du plan.
<blueprint-run-id> Remplacez-le par l'ID d'exécution du plan.

```
aws glue get-blueprint-run --blueprint-name <blueprint-name> --run-id <blueprint-run-id>
```

 Voir aussi :

- [Vue d'ensemble des plans dans AWS Glue](#)

AWS CloudFormation pour AWS Glue

AWS CloudFormation est un service qui permet de créer de nombreuses AWS ressources. AWS Glue fournit des opérations d'API pour créer des objets dans le AWS Glue Data Catalog. Cependant, il peut être plus pratique de définir et de créer AWS Glue objets et autres objets de AWS ressources connexes dans un fichier AWS CloudFormation modèle. Ensuite, vous pouvez automatiser le processus de création d'objets.

AWS CloudFormation fournit une syntaxe simplifiée, soit JSON (JavaScript Object Notation) soit YAML (YAML Ain't Markup Language), pour exprimer la création de ressources. AWS Vous pouvez utiliser les modèles AWS CloudFormation pour définir les objets de catalogue de données tels que les bases de données, les tables, les partitions, les crawlers, les classifieurs et les connexions. Vous pouvez également définir des objets ETL tels que les tâches, les déclencheurs et les points de terminaison de développement. Vous créez un modèle qui décrit toutes les AWS ressources que vous souhaitez, et vous vous AWS CloudFormation chargez de les approvisionner et de les configurer pour vous.

Pour plus d'informations, voir [Qu'est-ce que c'est AWS CloudFormation ?](#) et [Utilisation de AWS CloudFormation modèles](#) dans le guide de AWS CloudFormation l'utilisateur.

Si vous prévoyez d'utiliser AWS CloudFormation des modèles compatibles avec AWS Glue, en tant qu'administrateur, vous devez accorder l'accès aux AWS services et aux actions dont il dépend. AWS CloudFormation Pour accorder l'autorisation de créer AWS CloudFormation des ressources, associez la politique suivante aux utilisateurs qui travaillent avec AWS CloudFormation :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "cloudformation:*"
      ],
      "Resource": "*"
    }
  ]
}
```

Le tableau suivant répertorie les actions qu'un AWS CloudFormation modèle peut effectuer en votre nom. Il inclut des liens vers des informations sur les types de AWS ressources et leurs types de propriétés que vous pouvez ajouter à un AWS CloudFormation modèle.

AWS Glue ressource	AWS CloudFormation modèle	AWS Glue exemples
Classifieur	AWS::Glue::Classifier	classifieur Grok , classifieur JSON , classifieur XML
Connexion	AWS::Glue::Connection	Connexion MySQL
crawler	AWS::Glue::Crawler	Crawler Amazon S3 , Crawler MySQL
Base de données	AWS::Glue::Database	Base de données vide , Base de données avec tables
Point de terminaison de développement	AWS::Glue::DevEndpoint	Point de terminaison de développement
Tâche	AWS::Glue::Job	Tâche Amazon S3 , Tâche JDBC
Transformation de machine learning	AWS::Glue::MLTransform	Transformation de machine learning
Ensemble de règles de qualité des données	AWS::Glue::DataQualityEnsemble de règles	Ensemble de règles de qualité des données , Ensemble de règles de qualité des données avec planificateur EventBridge
Partition	AWS::Glue::Partition	Partitions d'une table
Tableau	AWS::Glue::Table	Table d'une base de données
Déclencheur	AWS::Glue::Trigger	Déclencheur à la demande , déclencheur planifié , déclencheur conditionnel

Pour démarrer, utilisez les exemples de modèles suivants et personnalisez-les avec vos propres métadonnées. Utilisez ensuite la AWS CloudFormation console pour créer une AWS CloudFormation pile à laquelle ajouter des objets AWS Glue et tous les services associés. De nombreux domaines dans un AWS Glue les objets sont facultatifs. Ces modèles illustrent les champs obligatoires ou nécessaires à un fonctionnement et à une fonctionnalité AWS Glue objet.

Un AWS CloudFormation modèle peut être au format JSON ou YAML. Dans ces exemples, YAML est utilisé pour faciliter la lisibilité. Les exemples contiennent des commentaires (#) pour décrire les valeurs qui sont définies dans les modèles.

AWS CloudFormation les modèles peuvent inclure une `Parameters` section. Cette section peut être modifiée dans le texte d'exemple ou lorsque le fichier YAML est soumis à la AWS CloudFormation console pour créer une pile. La `Resources` section du modèle contient la définition de AWS Glue et les objets associés. AWS CloudFormation les définitions de syntaxe des modèles peuvent contenir des propriétés qui incluent une syntaxe de propriété plus détaillée. Il se peut que toutes les propriétés ne soient pas nécessaires pour créer un AWS Glue objet. Ces exemples montrent des exemples de valeurs pour les propriétés communes permettant de créer un AWS Glue objet.

Exemple AWS CloudFormation de modèle pour un AWS Glue database

Un AWS Glue la base de données du catalogue de données contient des tables de métadonnées. La base de données comprend très peu de propriétés et peut être créée dans le catalogue de données à l'aide d'un AWS CloudFormation modèle. L'exemple de modèle suivant est fourni pour vous aider à démarrer et pour illustrer l'utilisation des AWS CloudFormation piles avec AWS Glue. La seule ressource créée par l'exemple de modèle est une base de données nommée `fn-mysampledatabase`. Vous pouvez le modifier en modifiant le texte de l'exemple ou en modifiant la valeur sur la AWS CloudFormation console lorsque vous soumettez le YAML.

Vous trouverez ci-dessous des exemples de valeurs pour les propriétés courantes permettant de créer un AWS Glue base de données. Pour plus d'informations sur le modèle AWS CloudFormation de base de données pour AWS Glue, voir [AWS::Glue::Database](#).

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CloudFormation template in YAML to demonstrate creating a database named
  mysampledatabase
```

```
# The metadata created in the Data Catalog points to the flights public S3 bucket
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:
  CFNDatabaseName:
    Type: String
    Default: cfn-mysampledatabse

# Resources section defines metadata for the Data Catalog
Resources:
  # Create an AWS Glue database
  CFNDatabaseFlights:
    Type: AWS::Glue::Database
    Properties:
      # The database is created in the Data Catalog for your account
      CatalogId: !Ref AWS::AccountId
      DatabaseInput:
        # The name of the database is defined in the Parameters section above
        Name: !Ref CFNDatabaseName
        Description: Database to hold tables for flights data
        LocationUri: s3://crawler-public-us-east-1/flight/2016/csv/
        #Parameters: Leave AWS database parameters blank
```

Exemple AWS CloudFormation de modèle pour un AWS Glue base de données, table et partition

Un AWS Glue La table contient les métadonnées qui définissent la structure et l'emplacement des données que vous souhaitez traiter avec vos scripts ETL. Dans une table, vous pouvez définir des partitions pour mettre en parallèle le traitement de vos données. Une partition est un fragment de données que vous avez défini avec une clé. Par exemple, en utilisant un mois en tant que clé, toutes les données de janvier se trouvent dans la même partition. Entrée AWS Glue, les bases de données peuvent contenir des tables et les tables peuvent contenir des partitions.

L'exemple suivant montre comment remplir une base de données, une table et des partitions à l'aide d'un modèle AWS CloudFormation . Le format des données de base est csv et délimité par une virgule (,). Comme une base de données doit exister avant qu'elle ne puisse contenir une table et qu'une table doit exister avant que les partitions ne puissent être créées, le modèle utilise l'instruction DependsOn pour définir la dépendance de ces objets lorsqu'ils sont créés.

Les valeurs de cet exemple définissent une table qui contient les données de vol à partir d'un compartiment Amazon S3 disponible publiquement. À des fins d'illustration, quelques colonnes de données et une clé de partitionnement sont définies. Quatre partitions sont également définies dans le catalogue de données. Certains champs pour décrire le stockage des données de base sont également affichés dans les champs `StorageDescriptor`.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CloudFormation template in YAML to demonstrate creating a database, a table,
# and partitions
# The metadata created in the Data Catalog points to the flights public S3 bucket
#
# Parameters substituted in the Resources section
# These parameters are names of the resources created in the Data Catalog
Parameters:
  CFNDatabaseName:
    Type: String
    Default: cfn-database-flights-1
  CFNTableName1:
    Type: String
    Default: cfn-manual-table-flights-1
# Resources to create metadata in the Data Catalog
Resources:
  ###
  # Create an AWS Glue database
  CFNDatabaseFlights:
    Type: AWS::Glue::Database
    Properties:
      CatalogId: !Ref AWS::AccountId
      DatabaseInput:
        Name: !Ref CFNDatabaseName
        Description: Database to hold tables for flights data
  ###
  # Create an AWS Glue table
  CFNTableFlights:
    # Creating the table waits for the database to be created
    DependsOn: CFNDatabaseFlights
    Type: AWS::Glue::Table
    Properties:
      CatalogId: !Ref AWS::AccountId
      DatabaseName: !Ref CFNDatabaseName
      TableInput:
```

```

    Name: !Ref CFNTableName1
    Description: Define the first few columns of the flights table
    TableType: EXTERNAL_TABLE
    Parameters: {
      "classification": "csv"
    }
#
    ViewExpandedText: String
    PartitionKeys:
      # Data is partitioned by month
      - Name: mon
        Type: bigint
    StorageDescriptor:
      OutputFormat: org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat
      Columns:
        - Name: year
          Type: bigint
        - Name: quarter
          Type: bigint
        - Name: month
          Type: bigint
        - Name: day_of_month
          Type: bigint
      InputFormat: org.apache.hadoop.mapred.TextInputFormat
      Location: s3://crawler-public-us-east-1/flight/2016/csv/
      SerdeInfo:
        Parameters:
          field.delim: ","
        SerializationLibrary: org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe
# Partition 1
# Create an AWS Glue partition
CFNPartitionMon1:
  DependsOn: CFNTableFlights
  Type: AWS::Glue::Partition
  Properties:
    CatalogId: !Ref AWS::AccountId
    DatabaseName: !Ref CFNDatabaseName
    TableName: !Ref CFNTableName1
    PartitionInput:
      Values:
        - 1
    StorageDescriptor:
      OutputFormat: org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat
      Columns:
        - Name: mon

```

```

        Type: bigint
        InputFormat: org.apache.hadoop.mapred.TextInputFormat
        Location: s3://crawler-public-us-east-1/flight/2016/csv/mon=1/
        SerdeInfo:
            Parameters:
                field.delim: ","
            SerializationLibrary: org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe
# Partition 2
# Create an AWS Glue partition
CFNPartitionMon2:
    DependsOn: CFNTableFlights
    Type: AWS::Glue::Partition
    Properties:
        CatalogId: !Ref AWS::AccountId
        DatabaseName: !Ref CFNDatabaseName
        TableName: !Ref CFNTableName1
        PartitionInput:
            Values:
                - 2
            StorageDescriptor:
                OutputFormat: org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat
                Columns:
                    - Name: mon
                      Type: bigint
                InputFormat: org.apache.hadoop.mapred.TextInputFormat
                Location: s3://crawler-public-us-east-1/flight/2016/csv/mon=2/
                SerdeInfo:
                    Parameters:
                        field.delim: ","
                    SerializationLibrary: org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe
# Partition 3
# Create an AWS Glue partition
CFNPartitionMon3:
    DependsOn: CFNTableFlights
    Type: AWS::Glue::Partition
    Properties:
        CatalogId: !Ref AWS::AccountId
        DatabaseName: !Ref CFNDatabaseName
        TableName: !Ref CFNTableName1
        PartitionInput:
            Values:
                - 3
            StorageDescriptor:
                OutputFormat: org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat

```



```

Columns:
- Name: mon
  Type: bigint
InputFormat: org.apache.hadoop.mapred.TextInputFormat
Location: s3://crawler-public-us-east-1/flight/2016/csv/mon=3/
SerdeInfo:
  Parameters:
    field.delim: ","
  SerializationLibrary: org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe
# Partition 4
# Create an AWS Glue partition
CFNPartitionMon4:
  DependsOn: CFNTableFlights
  Type: AWS::Glue::Partition
  Properties:
    CatalogId: !Ref AWS::AccountId
    DatabaseName: !Ref CFNDatabaseName
    TableName: !Ref CFNTableName1
    PartitionInput:
      Values:
        - 4
    StorageDescriptor:
      OutputFormat: org.apache.hadoop.hive ql.io.HiveIgnoreKeyTextOutputFormat
      Columns:
        - Name: mon
          Type: bigint
      InputFormat: org.apache.hadoop.mapred.TextInputFormat
      Location: s3://crawler-public-us-east-1/flight/2016/csv/mon=4/
      SerdeInfo:
        Parameters:
          field.delim: ","
        SerializationLibrary: org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe

```

Exemple AWS CloudFormation de modèle pour un AWS Glue classificateur grok

Un AWS Glue le classificateur détermine le schéma de vos données. Un type de classifieur utilise un modèle grok personnalisé pour mettre vos données en correspondance. Si le modèle correspond, le classificateur personnalisé est utilisé pour créer le schéma de votre table et définir la classification avec la valeur définie dans la définition du classificateur.

Cet exemple crée un classificateur qui crée un schéma avec une colonne nommée message et définit la classification avec la valeur greedy.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a classifier
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the classifier to be created
CFNClassifierName:
  Type: String
  Default: cfn-classifier-grok-one-column-1

#
#
# Resources section defines metadata for the Data Catalog
Resources:
# Create classifier that uses grok pattern to put all data in one column and classifies
it as "greedy".
CFNClassifierFlights:
  Type: AWS::Glue::Classifier
  Properties:
    GrokClassifier:
      #Grok classifier that puts all data in one column
      Name: !Ref CFNClassifierName
      Classification: greedy

      GrokPattern: "%{GREEDYDATA:message}"
      #CustomPatterns: none
```

Exemple AWS CloudFormation de modèle pour un AWS Glue Classificateur JSON

Un AWS Glue le classificateur détermine le schéma de vos données. Un type de classificateur personnalisé utilise une JsonPath chaîne définissant les données JSON à classer par le classificateur. AWS Glue prend en charge un sous-ensemble d'opérateurs pourJsonPath, comme décrit dans la section [Écrire des JsonPath classificateurs personnalisés](#).

Si le modèle correspond, le classifieur personnalisé est utilisé pour créer le schéma de votre table.

Cet exemple crée un classifieur qui crée un schéma à chaque enregistrement du tableau Records3 dans un objet.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a JSON classifier
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the classifier to be created
CFNClassifierName:
  Type: String
  Default: cfn-classifier-json-one-column-1

#
#
# Resources section defines metadata for the Data Catalog
Resources:
# Create classifier that uses a JSON pattern.
CFNClassifierFlights:
  Type: AWS::Glue::Classifier
  Properties:
    JSONClassifier:
      #JSON classifier
      Name: !Ref CFNClassifierName
      JsonPath: $.Records3[*]
```

Exemple AWS CloudFormation de modèle pour un AWS Glue Classificateur XML

Un AWS Glue le classificateur détermine le schéma de vos données. Un type de classifieur personnalisé spécifie une balise XML pour désigner l'élément qui contient chaque enregistrement dans un document XML en cours d'analyse. Si le modèle correspond, le classificateur personnalisé est utilisé pour créer le schéma de votre table et définir la classification avec la valeur définie dans la définition du classificateur.

Cet exemple crée un classifieur qui crée un schéma avec chaque enregistrement dans la balise Record et définit la classification sur XML.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating an XML classifier
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the classifier to be created
  CFNClassifierName:
    Type: String
    Default: cfn-classifier-xml-one-column-1

#
#
# Resources section defines metadata for the Data Catalog
Resources:
# Create classifier that uses the XML pattern and classifies it as "XML".
  CFNClassifierFlights:
    Type: AWS::Glue::Classifier
    Properties:
      XMLClassifier:
        #XML classifier
        Name: !Ref CFNClassifierName
        Classification: XML
        RowTag: <Records>
```

Exemple AWS CloudFormation de modèle pour un AWS Glue crawler pour Amazon S3

Un AWS Glue crawler crée des tables de métadonnées dans votre catalogue de données qui correspondent à vos données. Vous pouvez ensuite utiliser ces définitions de table en tant que sources et cibles dans vos tâches ETL.

Cet exemple crée un robot d'exploration, le rôle IAM requis et un AWS Glue base de données dans le catalogue de données. Lorsque cet crawler est exécuté, il endosse le rôle IAM et crée une table dans la base de données pour les données de vol publiques. La table est créée avec le préfixe

« cfn_sample_1_ ». Le rôle IAM créé par ce modèle permet des autorisations globales ; il se peut que vous vouliez créer un rôle personnalisé. Aucun classificateur personnalisé n'est défini par ce classificateur. AWS Glue les classificateurs intégrés sont utilisés par défaut.

Lorsque vous soumettez cet exemple à la AWS CloudFormation console, vous devez confirmer que vous souhaitez créer le rôle IAM.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a crawler
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the crawler to be created
  CFNCrawlerName:
    Type: String
    Default: cfn-crawler-flights-1
  CFNDatabaseName:
    Type: String
    Default: cfn-database-flights-1
  CFNTablePrefixName:
    Type: String
    Default: cfn_sample_1_
#
#
# Resources section defines metadata for the Data Catalog
Resources:
#Create IAM Role assumed by the crawler. For demonstration, this role is given all
permissions.
  CFNRoleFlights:
    Type: AWS::IAM::Role
    Properties:
      AssumeRolePolicyDocument:
        Version: "2012-10-17"
        Statement:
          -
            Effect: "Allow"
            Principal:
              Service:
                - "glue.amazonaws.com"
```

```

        Action:
          - "sts:AssumeRole"
    Path: "/"
    Policies:
      -
        PolicyName: "root"
        PolicyDocument:
          Version: "2012-10-17"
          Statement:
            -
              Effect: "Allow"
              Action: "*"
              Resource: "*"
# Create a database to contain tables created by the crawler
CFNDatabaseFlights:
  Type: AWS::Glue::Database
  Properties:
    CatalogId: !Ref AWS::AccountId
    DatabaseInput:
      Name: !Ref CFNDatabaseName
      Description: "AWS Glue container to hold metadata tables for the flights
crawler"
#Create a crawler to crawl the flights data on a public S3 bucket
CFNCrawlerFlights:
  Type: AWS::Glue::Crawler
  Properties:
    Name: !Ref CFNCrawlerName
    Role: !GetAtt CFNRoleFlights.Arn
    #Classifiers: none, use the default classifier
    Description: AWS Glue crawler to crawl flights data
    #Schedule: none, use default run-on-demand
    DatabaseName: !Ref CFNDatabaseName
    Targets:
      S3Targets:
        # Public S3 bucket with the flights data
        - Path: "s3://crawler-public-us-east-1/flight/2016/csv"
    TablePrefix: !Ref CFNTablePrefixName
    SchemaChangePolicy:
      UpdateBehavior: "UPDATE_IN_DATABASE"
      DeleteBehavior: "LOG"
    Configuration: "{\"Version\":\"1.0\",\"CrawlerOutput\":{\"Partitions\":{\"
AddOrUpdateBehavior\":\"InheritFromTable\"},\"Tables\":{\"AddOrUpdateBehavior\":
MergeNewColumns\"}}}"

```

Exemple AWS CloudFormation de modèle pour un AWS Glue connexion

Un AWS Glue une connexion dans le catalogue de données contient les informations JDBC et réseau requises pour se connecter à une base de données JDBC. Ces informations sont utilisées lorsque vous vous connectez à une base de données JDBC pour analyser ou exécuter des tâches ETL.

Cet exemple crée une connexion à une base de données MySQL Amazon RDS nommée devdb. Lorsque cette connexion est utilisée, un rôle IAM, les informations d'identification de base de données et les valeurs de connexion réseau doivent également être fournies. Consultez les détails des champs nécessaires du modèle.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a connection
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the connection to be created
  CFNConnectionName:
    Type: String
    Default: cfn-connection-mysql-flights-1
  CFNJDBCString:
    Type: String
    Default: "jdbc:mysql://xxx-mysql.yyyyyyyyyyyyyyyy.us-east-1.rds.amazonaws.com:3306/
devdb"
  CFNJDBCUser:
    Type: String
    Default: "master"
  CFNJDBCPassword:
    Type: String
    Default: "12345678"
    NoEcho: true
#
#
# Resources section defines metadata for the Data Catalog
Resources:
  CFNConnectionMySQL:
```

```
Type: AWS::Glue::Connection
Properties:
  CatalogId: !Ref AWS::AccountId
  ConnectionInput:
    Description: "Connect to MySQL database."
    ConnectionType: "JDBC"
    #MatchCriteria: none
    PhysicalConnectionRequirements:
      AvailabilityZone: "us-east-1d"
      SecurityGroupIdList:
        - "sg-7d52b812"
      SubnetId: "subnet-84f326ee"
    ConnectionProperties: {
      "JDBC_CONNECTION_URL": !Ref CFNJDBCString,
      "USERNAME": !Ref CFNJDBCUser,
      "PASSWORD": !Ref CFNJDBCPassword
    }
  Name: !Ref CFNConnectionName
```

Exemple AWS CloudFormation de modèle pour un AWS Glue crawler pour JDBC

Un AWS Glue crawler crée des tables de métadonnées dans votre catalogue de données qui correspondent à vos données. Vous pouvez ensuite utiliser ces définitions de table en tant que sources et cibles dans vos tâches ETL.

Cet exemple crée un robot d'exploration, le rôle IAM requis et un AWS Glue base de données dans le catalogue de données. Lorsque cet crawler est exécuté, il endosse le rôle IAM et crée une table dans la base de données pour les données de vol publiques qui ont été stockées dans une base de données MySQL. La table est créée avec le préfixe « `cf_n_jdbc_1_` ». Le rôle IAM créé par ce modèle permet des autorisations globales ; il se peut que vous vouliez créer un rôle personnalisé. Aucun classificateur personnalisé ne peut être défini pour les données JDBC. AWS Glue les classificateurs intégrés sont utilisés par défaut.

Lorsque vous soumettez cet exemple à la AWS CloudFormation console, vous devez confirmer que vous souhaitez créer le rôle IAM.

```
---
AWSTemplateFormatVersion: '2010-09-09'
```



```
# Sample CFN YAML to demonstrate creating a crawler
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the crawler to be created
  CFNCrawlerName:
    Type: String
    Default: cfn-crawler-jdbc-flights-1
# The name of the database to be created to contain tables
  CFNDatabaseName:
    Type: String
    Default: cfn-database-jdbc-flights-1
# The prefix for all tables crawled and created
  CFNTablePrefixName:
    Type: String
    Default: cfn_jdbc_1_
# The name of the existing connection to the MySQL database
  CFNConnectionName:
    Type: String
    Default: cfn-connection-mysql-flights-1
# The name of the JDBC path (database/schema/table) with wildcard (%) to crawl
  CFNJDBCPath:
    Type: String
    Default: saldev/%
#
#
# Resources section defines metadata for the Data Catalog
Resources:
#Create IAM Role assumed by the crawler. For demonstration, this role is given all
permissions.
  CFNRoleFlights:
    Type: AWS::IAM::Role
    Properties:
      AssumeRolePolicyDocument:
        Version: "2012-10-17"
        Statement:
          -
            Effect: "Allow"
            Principal:
              Service:
                - "glue.amazonaws.com"
            Action:
```

```

        - "sts:AssumeRole"
    Path: "/"
    Policies:
      -
        PolicyName: "root"
        PolicyDocument:
          Version: "2012-10-17"
          Statement:
            -
              Effect: "Allow"
              Action: "*"
              Resource: "*"
# Create a database to contain tables created by the crawler
CFNDatabaseFlights:
  Type: AWS::Glue::Database
  Properties:
    CatalogId: !Ref AWS::AccountId
    DatabaseInput:
      Name: !Ref CFNDatabaseName
      Description: "AWS Glue container to hold metadata tables for the flights
crawler"
#Create a crawler to crawl the flights data in MySQL database
CFNCrawlerFlights:
  Type: AWS::Glue::Crawler
  Properties:
    Name: !Ref CFNCrawlerName
    Role: !GetAtt CFNRoleFlights.Arn
    #Classifiers: none, use the default classifier
    Description: AWS Glue crawler to crawl flights data
    #Schedule: none, use default run-on-demand
    DatabaseName: !Ref CFNDatabaseName
    Targets:
      JdbcTargets:
        # JDBC MySQL database with the flights data
        - ConnectionName: !Ref CFNConnectionName
          Path: !Ref CFNJDBCPath
        #Exclusions: none
    TablePrefix: !Ref CFNTablePrefixName
    SchemaChangePolicy:
      UpdateBehavior: "UPDATE_IN_DATABASE"
      DeleteBehavior: "LOG"

```

```
Configuration: "{\"Version\":1.0,\"CrawlerOutput\":{\"Partitions\":{\"AddOrUpdateBehavior\":{\"InheritFromTable\"},\"Tables\":{\"AddOrUpdateBehavior\":{\"MergeNewColumns\"}}}}"
```

Exemple AWS CloudFormation de modèle pour un AWS Glue job pour Amazon S3 vers Amazon S3

Un AWS Glue une tâche du catalogue de données contient les valeurs de paramètres requises pour exécuter un script dans AWS Glue.

Cet exemple crée une tâche qui lit les données de vol à partir d'un compartiment Amazon S3 dans un format csv et les écrit dans un fichier Parquet Amazon S3. Le script qui est exécuté par cette tâche doit déjà exister. Vous pouvez générer un script ETL pour votre environnement à l'aide du AWS Glue console. Lorsque la tâche est exécutée, un rôle IAM avec les autorisations appropriées doit également être fourni.

Les valeurs courantes des paramètres sont affichées dans le modèle. Par exemple, `AllocatedCapacity` (DPUs) prend par défaut la valeur 5.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a job using the public flights S3 table in a
public bucket
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the job to be created
CFNJobName:
  Type: String
  Default: cfn-job-S3-to-S3-2
# The name of the IAM role that the job assumes. It must have access to data, script,
temporary directory
CFNIAMRoleName:
  Type: String
  Default: AWSGlueServiceRoleGA
# The S3 path where the script for this job is located
CFNScriptLocation:
  Type: String
```

```

    Default: s3://aws-glue-scripts-123456789012-us-east-1/myid/sal-job-test2
#
#
# Resources section defines metadata for the Data Catalog
Resources:
# Create job to run script which accesses flightscsv table and write to S3 file as
parquet.
# The script already exists and is called by this job
CFNJobFlights:
  Type: AWS::Glue::Job
  Properties:
    Role: !Ref CFNIAMRoleName
    #DefaultArguments: JSON object
    # If script written in Scala, then set DefaultArguments={'--job-language';
'scala', '--class': 'your scala class'}
    #Connections: No connection needed for S3 to S3 job
    # ConnectionsList
    #MaxRetries: Double
    Description: Job created with CloudFormation
    #LogUri: String
    Command:
      Name: glueetl
      ScriptLocation: !Ref CFNScriptLocation
        # for access to directories use proper IAM role with permission to buckets
and folders that begin with "aws-glue-"
        # script uses temp directory from job definition if required (temp
directory not used S3 to S3)
        # script defines target for output as s3://aws-glue-target/sal
    AllocatedCapacity: 5
    ExecutionProperty:
      MaxConcurrentRuns: 1
    Name: !Ref CFNJobName

```

Exemple AWS CloudFormation de modèle pour un AWS Glue job pour JDBC vers Amazon S3

Un AWS Glue une tâche du catalogue de données contient les valeurs de paramètres requises pour exécuter un script dans AWS Glue.

Cet exemple crée une tâche qui lit les données de vol à partir d'une base de données JDBC MySQL comme définie par la connexion nommée `cfn-connection-mysql-flights-1` et les écrit dans

un fichier Parquet Amazon S3. Le script qui est exécuté par cette tâche doit déjà exister. Vous pouvez générer un script ETL pour votre environnement à l'aide du AWS Glue console. Lorsque la tâche est exécutée, un rôle IAM avec les autorisations appropriées doit également être fourni.

Les valeurs courantes des paramètres sont affichées dans le modèle. Par exemple, `AllocatedCapacity` (DPUs) prend par défaut la valeur 5.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a job using a MySQL JDBC DB with the flights
# data to an S3 file
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the job to be created
  CFNJobName:
    Type: String
    Default: cfn-job-JDBC-to-S3-1
# The name of the IAM role that the job assumes. It must have access to data, script,
# temporary directory
  CFNIAMRoleName:
    Type: String
    Default: AWSGlueServiceRoleGA
# The S3 path where the script for this job is located
  CFNScriptLocation:
    Type: String
    Default: s3://aws-glue-scripts-123456789012-us-east-1/myid/sal-job-dec4a
# The name of the connection used for JDBC data source
  CFNConnectionName:
    Type: String
    Default: cfn-connection-mysql-flights-1
#
#
# Resources section defines metadata for the Data Catalog
Resources:
# Create job to run script which accesses JDBC flights table via a connection and write
# to S3 file as parquet.
# The script already exists and is called by this job
  CFNJobFlights:
    Type: AWS::Glue::Job
```

```

Properties:
  Role: !Ref CFNIAMRoleName
  #DefaultArguments: JSON object
  # For example, if required by script, set temporary directory as
DefaultArguments={'--TempDir'; 's3://aws-glue-temporary-xyc/sal'}
  Connections:
    Connections:
      - !Ref CFNConnectionName
  #MaxRetries: Double
  Description: Job created with CloudFormation using existing script
  #LogUri: String
  Command:
    Name: glueetl
    ScriptLocation: !Ref CFNScriptLocation
      # for access to directories use proper IAM role with permission to buckets
and folders that begin with "aws-glue-"
      # if required, script defines temp directory as argument TempDir and used
in script like redshift_tmp_dir = args["TempDir"]
      # script defines target for output as s3://aws-glue-target/sal
  AllocatedCapacity: 5
  ExecutionProperty:
    MaxConcurrentRuns: 1
  Name: !Ref CFNJobName

```

Exemple AWS CloudFormation de modèle pour un AWS Glue déclencheur à la demande

Un AWS Glue le déclencheur du catalogue de données contient les valeurs des paramètres nécessaires pour démarrer une tâche lorsque le déclencheur se déclenche. Un déclencheur à la demande s'exécute lorsque vous l'activez.

Cet exemple crée un déclencheur à la demande qui démarre une tâche nommée `cfn-job-S3-to-S3-1`.

```

---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating an on-demand trigger
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog

```

```

Parameters:
  # The existing job to be started by this trigger
  CFNJobName:
    Type: String
    Default: cfn-job-S3-to-S3-1
  # The name of the trigger to be created
  CFNTriggerName:
    Type: String
    Default: cfn-trigger-ondemand-flights-1
#
# Resources section defines metadata for the Data Catalog
# Sample CFN YAML to demonstrate creating an on-demand trigger for a job
Resources:
  # Create trigger to run an existing job (CFNJobName) on an on-demand schedule.
  CFNTriggerSample:
    Type: AWS::Glue::Trigger
    Properties:
      Name:
        Ref: CFNTriggerName
      Description: Trigger created with CloudFormation
      Type: ON_DEMAND
      Actions:
        - JobName: !Ref CFNJobName
          # Arguments: JSON object
      #Schedule:
      #Predicate:

```

Exemple AWS CloudFormation de modèle pour un AWS Glue déclencheur programmé

Un AWS Glue le déclencheur du catalogue de données contient les valeurs des paramètres nécessaires pour démarrer une tâche lorsque le déclencheur se déclenche. Un déclencheur planifié est exécuté lorsqu'il est activé et que le minuteur cron s'affiche.

Cet exemple crée un déclencheur planifié qui démarre une tâche nommée `cfn-job-S3-to-S3-1`. Le minuteur est une expression cron qui permet d'exécuter la tâche toutes les 10 minutes du lundi au vendredi.

```

---
AWSTemplateFormatVersion: '2010-09-09'

```

```
# Sample CFN YAML to demonstrate creating a scheduled trigger
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:
  # The existing job to be started by this trigger
  CFNJobName:
    Type: String
    Default: cfn-job-S3-to-S3-1
  # The name of the trigger to be created
  CFNTriggerName:
    Type: String
    Default: cfn-trigger-scheduled-flights-1
#
# Resources section defines metadata for the Data Catalog
# Sample CFN YAML to demonstrate creating a scheduled trigger for a job
#
Resources:
# Create trigger to run an existing job (CFNJobName) on a cron schedule.
  TriggerSample1CFN:
    Type: AWS::Glue::Trigger
    Properties:
      Name:
        Ref: CFNTriggerName
      Description: Trigger created with CloudFormation
      Type: SCHEDULED
      Actions:
        - JobName: !Ref CFNJobName
        # Arguments: JSON object
        # # Run the trigger every 10 minutes on Monday to Friday
        Schedule: cron(0/10 * ? * MON-FRI *)
      #Predicate:
```

Exemple AWS CloudFormation de modèle pour un AWS Glue déclencheur conditionnel

Un AWS Glue le déclencheur du catalogue de données contient les valeurs des paramètres nécessaires pour démarrer une tâche lorsque le déclencheur se déclenche. Un déclencheur conditionnel est exécuté lorsqu'il est activé et que ses conditions sont satisfaites, comme un travail terminé avec succès.

Cet exemple crée un déclencheur conditionnel qui démarre une tâche nommée `cfn-job-S3-to-S3-1`. Cette tâche commence lorsque la tâche nommée `cfn-job-S3-to-S3-2` se termine correctement.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a conditional trigger for a job, which starts
# when another job completes
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:
  # The existing job to be started by this trigger
  CFNJobName:
    Type: String
    Default: cfn-job-S3-to-S3-1
  # The existing job that when it finishes causes trigger to fire
  CFNJobName2:
    Type: String
    Default: cfn-job-S3-to-S3-2
  # The name of the trigger to be created
  CFNTriggerName:
    Type: String
    Default: cfn-trigger-conditional-1
#
Resources:
# Create trigger to run an existing job (CFNJobName) when another job completes
# (CFNJobName2).
  CFNTriggerSample:
    Type: AWS::Glue::Trigger
    Properties:
      Name:
        Ref: CFNTriggerName
      Description: Trigger created with CloudFormation
      Type: CONDITIONAL
      Actions:
        - JobName: !Ref CFNJobName
          # Arguments: JSON object
      #Schedule: none
      Predicate:
        #Value for Logical is required if more than 1 job listed in Conditions
        Logical: AND
```

Conditions:

- LogicalOperator: EQUALS
JobName: !Ref CFNJobName2
State: SUCCEEDED

Exemple AWS CloudFormation de modèle pour un AWS Glue terminal de développement

Un AWS Glue la transformation de l'apprentissage automatique est une transformation personnalisée visant à nettoyer vos données. Il existe actuellement une transformation disponible nommée FindMatches. La FindMatches transformation vous permet d'identifier les enregistrements dupliqués ou correspondants dans votre ensemble de données, même lorsque les enregistrements n'ont pas d'identifiant unique commun et qu'aucun champ ne correspond exactement.

Cet exemple crée une transformation de machine learning. Pour plus d'informations sur les paramètres dont vous avez besoin pour créer une transformation de machine learning, consultez [Record correspondant à AWS Lake Formation FindMatches](#).

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a machine learning transform
#
# Resources section defines metadata for the machine learning transform
Resources:
  MyMLTransform:
    Type: "AWS::Glue::MLTransform"
    Condition: "isGlueMLGARegion"
    Properties:
      Name: !Sub "MyTransform"
      Description: "The bestest transform ever"
      Role: !ImportValue MyMLTransformUserRole
      GlueVersion: "1.0"
      WorkerType: "Standard"
      NumberOfWorkers: 5
      Timeout: 120
      MaxRetries: 1
      InputRecordTables:
        GlueTables:
          - DatabaseName: !ImportValue MyMLTransformDatabase
            TableName: !ImportValue MyMLTransformTable
```

```

TransformParameters:
  TransformType: "FIND_MATCHES"
  FindMatchesParameters:
    PrimaryKeyColumnName: "testcolumn"
    PrecisionRecallTradeoff: 0.5
    AccuracyCostTradeoff: 0.5
    EnforceProvidedLabels: True
  Tags:
    key1: "value1"
    key2: "value2"
  TransformEncryption:
    TaskRunSecurityConfigurationName: !ImportValue
MyMLTransformSecurityConfiguration
  MLUserDataEncryption:
    MLUserDataEncryptionMode: "SSE-KMS"
    KmsKeyId: !ImportValue MyMLTransformEncryptionKey

```

Exemple AWS CloudFormation de modèle pour un AWS Glue Data Quality jeu de règles

Un ensemble de règles relatives à la qualité des AWS Glue données contient des règles qui peuvent être évaluées sur une table du catalogue de données. Une fois que l'ensemble de règles est placé sur votre table cible, vous pouvez accéder au catalogue de données et exécuter une évaluation qui confronte vos données aux règles de l'ensemble de règles. Ces règles peuvent aller de l'évaluation du nombre de lignes à l'évaluation de l'intégrité référentielle de vos données.

L'exemple suivant est un CloudFormation modèle qui crée un ensemble de règles avec une variété de règles sur la table cible spécifiée.

```

AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a DataQualityRuleset
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

  # The name of the ruleset to be created
  RulesetName:
    Type: String
    Default: "CFNRulesetName"
  RulesetDescription:

```

```

    Type: String
    Default: "CFN DataQualityRuleset"
# Rules that will be associated with this ruleset
Rules:
  Type: String
  Default: 'Rules = [
    RowCount > 100,
    IsUnique "id",
    IsComplete "nametype"
  ]'
# Name of database and table within Data Catalog which the ruleset will
# be applied too
DatabaseName:
  Type: String
  Default: "ExampleDatabaseName"
TableName:
  Type: String
  Default: "ExampleTableName"

# Resources section defines metadata for the Data Catalog
Resources:
  # Creates a Data Quality ruleset under specified rules
  DQRuleset:
    Type: AWS::Glue::DataQualityRuleset
    Properties:
      Name: !Ref RulesetName
      Description: !Ref RulesetDescription
      # The String within rules must be formatted in DQDL, a language
      # used specifically to make rules
      Ruleset: !Ref Rules
      # The targeted table must exist within Data Catalog alongside
      # the correct database
      TargetTable:
        DatabaseName: !Ref DatabaseName
        TableName: !Ref TableName

```

Exemple AWS CloudFormation de modèle pour un AWS Glue Data Quality ensemble de règles avec planificateur EventBridge

Un ensemble de règles relatives à la qualité des AWS Glue données contient des règles qui peuvent être évaluées sur une table du catalogue de données. Une fois que l'ensemble de règles est placé sur votre table cible, vous pouvez accéder au catalogue de données et exécuter une évaluation qui

confronte vos données aux règles de l'ensemble de règles. Au lieu d'avoir à accéder manuellement au catalogue de données pour évaluer l'ensemble de règles, vous pouvez également ajouter un EventBridge planificateur dans notre CloudFormation modèle pour planifier ces évaluations d'ensembles de règles pour vous à intervalles réguliers.

L'exemple suivant est un CloudFormation modèle qui crée un ensemble de règles de qualité des données et un EventBridge planificateur pour évaluer l'ensemble de règles susmentionné toutes les cinq minutes.

```
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a DataQualityRuleset
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

  # The name of the ruleset to be created
  RulesetName:
    Type: String
    Default: "CFNRulesetName"
  # Rules that will be associated with this Ruleset
  Rules:
    Type: String
    Default: 'Rules = [
      RowCount > 100,
      IsUnique "id",
      IsComplete "nametype"
    ]'
  # The name of the Schedule to be created
  ScheduleName:
    Type: String
    Default: "ScheduleDQRulsetEvaluation"
  # This expression determines the rate at which the Schedule will evaluate
  # your data using the above ruleset
  ScheduleRate:
    Type: String
    Default: "rate(5 minutes)"
  # The Request that being sent must match the details of the Data Quality Ruleset
  ScheduleRequest:
    Type: String
    Default: '
      { "DataSource": { "GlueTable": { "DatabaseName": "ExampleDatabaseName",
        "TableName": "ExampleTableName" } },
```

```

        "Role": "role/AWSGlueServiceRoleDefault",
        "RulesetNames": [ "CFNRulesetName" ] }
    ,

# Resources section defines metadata for the Data Catalog
Resources:
    # Creates a Data Quality ruleset under specified rules
    DQRuleset:
        Type: AWS::Glue::DataQualityRuleset
        Properties:
            Name: !Ref RulesetName
            Description: "CFN DataQualityRuleset"
            # The String within rules must be formatted in DQDL, a language
            # used specifically to make rules
            Ruleset: !Ref Rules
            # The targeted table must exist within Data Catalog alongside
            # the correct database
            TargetTable:
                DatabaseName: "ExampleDatabaseName"
                TableName: "ExampleTableName"
    # Create a Scheduler to schedule evaluation runs on the above ruleset
    ScheduledDQEval:
        Type: AWS::Scheduler::Schedule
        Properties:
            Name: !Ref ScheduleName
            Description: "Schedule DataQualityRuleset Evaluations"
            FlexibleTimeWindow:
                Mode: "OFF"
            ScheduleExpression: !Ref ScheduleRate
            ScheduleExpressionTimezone: "America/New_York"
            State: "ENABLED"
            Target:
                # The ARN is the API that will be run, since we want to evaluate our ruleset
                # we want this specific ARN
                Arn: "arn:aws:scheduler::aws-sdk:glue:startDataQualityRulesetEvaluationRun"
                # Your RoleArn must have approval to schedule
                RoleArn: "arn:aws:iam::123456789012:role/AWSGlueServiceRoleDefault"
                # This is the Request that is being sent to the Arn
                Input: '
                    { "DataSource": { "GlueTable": { "DatabaseName": "sampledb", "TableName":
"meteorite" } },
                    "Role": "role/AWSGlueServiceRoleDefault",
                    "RulesetNames": [ "TestCFN" ] }

```

Exemple AWS CloudFormation de modèle pour un AWS Glue terminal de développement

Un AWS Glue le point de terminaison de développement est un environnement que vous pouvez utiliser pour développer et tester votre AWS Glue scripts.

Cet exemple crée un point de terminaison de développement avec les valeurs de paramètres réseau minimales requises pour le créer avec succès. Pour plus d'informations sur les paramètres dont vous avez besoin pour configurer un point de terminaison de développement, consultez [Mise en place d'un réseau pour le développement de AWS Glue](#).

Vous fournissez un ARN (Amazon Resource Name) de rôle IAM existant pour créer le point de terminaison de développement. Fournissez une clé publique RSA valide et conservez la clé privée correspondante disponible si vous prévoyez de créer un serveur de bloc-notes sur le point de terminaison de développement.

Note

Dans le cas d'un serveur de bloc-notes que vous créez qui est associé à un point de terminaison de développement, vous le gérez. Par conséquent, si vous supprimez le point de terminaison de développement, pour supprimer le serveur bloc-notes, vous devez supprimer la AWS CloudFormation pile sur la AWS CloudFormation console.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a development endpoint
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the crawler to be created
CFNEndpointName:
  Type: String
  Default: cfn-devendpoint-1
```

```
CFNIAMRoleArn:
  Type: String
  Default: arn:aws:iam::123456789012/role/AWSGlueServiceRoleGA
#
#
# Resources section defines metadata for the Data Catalog
Resources:
  CFNDevEndpoint:
    Type: AWS::Glue::DevEndpoint
    Properties:
      EndpointName: !Ref CFNEndpointName
      #ExtraJarsS3Path: String
      #ExtraPythonLibsS3Path: String
      NumberOfNodes: 5
      PublicKey: ssh-rsa public.....key myuserid-key
      RoleArn: !Ref CFNIAMRoleArn
      SecurityGroupIds:
        - sg-64986c0b
      SubnetId: subnet-c67cccac
```


AWS Glue guide de programmation

Un script contient le code qui extrait les données des sources, les transforme et les charge dans des cibles. AWS Glue exécute un script lorsqu'il démarre une tâche.

AWS Glue Les scripts ETL sont codés en Python ou en Scala. Bien que tous les types de tâches puissent être écrits en Python, les tâches AWS Glue pour Spark peuvent également être écrites en Scala. Lorsque vous générez automatiquement la logique du code source de votre tâche dans AWS Glue Studio, un script est créé. Vous pouvez modifier ce script ou fournir votre propre script personnalisé pour effectuer votre travail ETL.

Fournir vos propres scripts personnalisés

Les scripts exécutent les tâches d'extraction, de transformation et de chargement (ETL) AWS Glue. Un script est créé lorsque vous générez automatiquement la logique de code source pour une tâche. Vous pouvez modifier ce script généré ou fournir votre propre script personnalisé.

Pour fournir votre propre script personnalisé AWS Glue, suivez les étapes générales suivantes :

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez l'onglet Tâches ETL, puis consultez la section Créer une tâche. Choisissez une option d'éditeur de script.
3. Sous This job runs (Cette tâche exécute), choisissez l'une des actions suivantes :
 - Créer un script avec du code standard
 - Charger et modifier un script existant
4. Sur la page Détails de la tâche, choisissez le rôle IAM requis pour l'exécution de votre script personnalisé. Pour de plus amples informations, veuillez consulter [Gestion des identités et des accès pour AWS Glue](#).
5. Choisissez les connexions référencées par votre script. Ces objets sont requis pour la connexion aux magasins de données JDBC nécessaires.

Une interface réseau Elastic est une interface réseau virtuelle que vous pouvez attacher à une instance dans un cloud privé virtuel (VPC). Choisissez l'interface réseau Elastic requise pour la connexion au magasin de données utilisé dans le script.

6. Fournissez une configuration supplémentaire, y compris des paramètres, spécifiques à votre type de tâche. Pour plus d'informations sur la configuration de votre type de tâche, consultez la section [Création de tâches ETL visuelles avec AWS Glue Studio](#).
7. Dans l'onglet Script, collez ou écrivez votre script personnalisé.

Utilisez le contenu de cette section pour vous guider dans le processus d'écriture de votre script personnalisé.

Pour plus d'informations sur l'ajout de tâches AWS Glue, consultez [Création de tâches ETL visuelles avec AWS Glue Studio](#).

Pour step-by-step obtenir des conseils, consultez le didacticiel [Ajouter une tâche dans la AWS Glue console](#).

Programmation de scripts Spark

AWS Glue facilite l'écriture ou la génération automatique de scripts d'extraction, de transformation et de chargement (ETL), en plus de les tester et de les exécuter. Cette section décrit les extensions pour Apache Spark introduites par AWS Glue et fournit des exemples de codage et d'exécution de scripts ETL en Python et en Scala.

Important

Les différentes versions de AWS Glue sont compatibles avec différentes versions d'Apache Spark. Votre script personnalisé doit être compatible avec la version Apache Spark prise en charge. Pour plus d'informations sur les versions de AWS Glue, consultez le [Glue version job property](#).

Rubriques

- [Tutoriel : Écrire un script AWS Glue for Spark](#)
- [Programmez les scripts ETL AWS Glue dans PySpark](#)
- [Programmation AWS Glue Scripts ETL dans Scala](#)
- [Fonctionnalités et optimisations pour la programmation AWS Glue pour les scripts Spark ETL](#)

Tutoriel : Écrire un script AWS Glue for Spark

Ce didacticiel vous présente le processus d'écriture des scripts AWS Glue. Vous pouvez exécuter des scripts selon un calendrier avec des tâches, ou de manière interactive avec des sessions interactives. Pour plus d'informations sur les tâches, consultez [Création de tâches ETL visuelles avec AWS Glue Studio](#). Pour plus d'informations sur les sessions interactives, consultez [the section called "Vue d'ensemble de AWS Glue sessions interactives"](#).

L'éditeur visuel AWS Glue Studio propose une interface graphique sans code pour créer des tâches AWS Glue. Les scripts Glue soutiennent les tâches visuelles. Ils vous donnent accès à l'ensemble étendu d'outils disponibles pour travailler avec les programmes Apache Spark. Vous pouvez accéder aux bibliothèques natives Spark APIs et AWS Glue qui facilitent les flux de travail d'extraction, de transformation et de chargement (ETL) à partir d'un script AWS Glue.

Dans ce didacticiel, vous allez extraire, transformer et charger un jeu de données de tickets de stationnement. Le script qui effectue ce travail est identique en termes de forme et de fonction à celui généré dans [Making ETL easy with AWS Glue Studio](#) sur le blog AWS Big Data, qui présente l'éditeur visuel AWS Glue Studio. En exécutant ce script dans une tâche, vous pouvez le comparer à des tâches visuelles et voir comment fonctionnent les scripts AWS Glue ETL. Cela vous prépare à utiliser des fonctionnalités supplémentaires qui ne sont pas encore disponibles dans les tâches visuels.

Vous utilisez le langage et les bibliothèques Python dans ce didacticiel. Des fonctionnalités similaires sont disponibles dans Scala. Après avoir suivi ce didacticiel, vous devriez être en mesure de générer et d'inspecter un exemple de script Scala pour comprendre comment exécuter le processus d'écriture de script Scala AWS Glue ETL.

Prérequis

Ce didacticiel nécessite la configuration suivante :

- Les mêmes prérequis que dans le billet de blog de AWS Glue Studio, qui vous demande d'exécuter un AWS CloudFormation modèle.

Ce modèle utilise le catalogue de données AWS Glue pour gérer le jeu de données des tickets de stationnement disponible dans `s3://aws-bigdata-blog/artifacts/gluestudio/`. Il crée les ressources suivantes, qui seront référencées par la suite :

- AWS Glue Studio Rôle : rôle IAM à exécuter AWS Glue jobs

- AWS Glue StudioAmazon S3Bucket : nom du compartiment Amazon S3 pour stocker les fichiers liés au blog
- AWS Glue StudioBillets/YYZDB — AWS Glue Base de données du catalogue de données
- AWS Glue StudioTableTickets— Table du catalogue de données à utiliser comme source
- AWS Glue StudioTableTrials— Table du catalogue de données à utiliser comme source
- AWS Glue StudioParkingTicketCount — Table du catalogue de données à utiliser comme destination
- Le script généré dans le billet de blog de AWS Glue Studio. Si des modifications sont apportées au billet de blog, le script est également disponible dans le texte suivant.

Génération d'un exemple de script

Vous pouvez utiliser l'éditeur visuel AWS Glue Studio comme un puissant outil de génération de code pour créer un échafaudage pour le script que vous souhaitez écrire. Vous allez utiliser cet outil pour créer un exemple de script.

Si vous voulez ignorer ces étapes, le script est fourni.

Exemple de script de didacticiel

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args["JOB_NAME"], args)

# Script generated for node S3 bucket
S3bucket_node1 = glueContext.create_dynamic_frame.from_catalog(
    database="yyz-tickets", table_name="tickets", transformation_ctx="S3bucket_node1"
)
```


```
# Script generated for node ApplyMapping
ApplyMapping_node2 = ApplyMapping.apply(
    frame=S3bucket_node1,
    mappings=[
        ("tag_number_masked", "string", "tag_number_masked", "string"),
        ("date_of_infraction", "string", "date_of_infraction", "string"),
        ("ticket_date", "string", "ticket_date", "string"),
        ("ticket_number", "decimal", "ticket_number", "float"),
        ("officer", "decimal", "officer_name", "decimal"),
        ("infraction_code", "decimal", "infraction_code", "decimal"),
        ("infraction_description", "string", "infraction_description", "string"),
        ("set_fine_amount", "decimal", "set_fine_amount", "float"),
        ("time_of_infraction", "decimal", "time_of_infraction", "decimal"),
    ],
    transformation_ctx="ApplyMapping_node2",
)

# Script generated for node S3 bucket
S3bucket_node3 = glueContext.write_dynamic_frame.from_options(
    frame=ApplyMapping_node2,
    connection_type="s3",
    format="glueparquet",
    connection_options={"path": "s3://DOC-EXAMPLE-BUCKET", "partitionKeys": []},
    format_options={"compression": "gzip"},
    transformation_ctx="S3bucket_node3",
)

job.commit()
```

Générer un exemple de script

1. Terminez le didacticiel AWS Glue Studio. Pour terminer ce didacticiel, voir [Création d'une tâche dans AWS Glue Studio à partir d'un exemple de tâche](#).
2. Accédez à l'onglet Scriptsur la page de la tâche, comme illustré dans la capture d'écran suivante :



3. Copiez l'intégralité du contenu de l'onglet Script. En définissant le langage de script dans Job details (Détails de la tâche), vous pouvez alterner entre la génération de code Python ou Scala.

Étape 1. Créer une tâche et coller votre script

Au cours de cette étape, vous allez créer une tâche AWS Glue dans le AWS Management Console. Cela permet de configurer une configuration qui permet à AWS Glue d'exécuter votre script. Elle crée également un espace dans lequel vous pouvez stocker et modifier votre script.

Pour créer une tâche

1. Dans le AWS Management Console, accédez à la page d'accueil de AWS Glue.
2. Dans le panneau de navigation, choisissez Tâches.
3. Choisissez Spark script editor (Éditeur de script Spark) dans Create job (Créer une tâche), puis Create (Créer).
4. Facultatif - Collez le texte intégral de votre script dans le volet Script. Vous pouvez également suivre le didacticiel.

Étape 2. Importer des bibliothèques AWS Glue

Vous devez configurer votre script pour interagir avec le code et la configuration qui sont définis en dehors du script. Ce travail est réalisé dans les coulisses de AWS Glue Studio.

Dans cette étape, vous effectuez les actions suivantes.

- Importer et initialiser un objet `GlueContext`. Il s'agit de l'importation la plus importante, du point de vue de l'écriture de scripts. Elle vous présente les méthodes standards pour définir les jeux de données source et cible, qui sont le point de départ de tout script ETL. Pour en savoir plus sur la classe `GlueContext`, consultez [GlueContext classe](#).
- Initialisation d'un `SparkContext` et d'une `SparkSession`. Ils vous permettent de configurer le moteur Spark disponible dans le job AWS Glue. Vous n'aurez pas besoin de les utiliser directement dans les scripts d'introduction de AWS Glue.
- Appelez `getResolvedOptions` pour préparer vos arguments de tâche à utiliser dans le script. Pour plus d'informations sur la résolution des paramètres de la tâche, consultez [the section called “getResolvedOptions”](#).
- Initialisation d'une Job. L'Jobobjet définit la configuration et suit l'état des différentes fonctionnalités optionnelles de AWS Glue. Votre script peut s'exécuter sans objet Job, mais il est recommandé de l'initialiser afin d'éviter toute confusion si ces fonctionnalités sont intégrées ultérieurement.

L'une de ces fonctionnalités concerne les signets de tâche, que vous pouvez éventuellement configurer dans ce didacticiel. Vous pouvez en savoir plus sur les signets de tâche dans la section suivante, [the section called “Facultatif : activer les signets de tâche”](#).

Dans cette procédure, vous écrivez le code suivant. Ce code fait partie de l'exemple de script généré.

```
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
```

```
job.init(args["JOB_NAME"], args)
```

Pour importer des bibliothèques AWS Glue

- Copiez cette section de code et collez-la dans l'éditeur Script.

 Note

Vous pourriez considérer la copie de code comme une mauvaise pratique d'ingénierie. Dans ce didacticiel, nous vous le suggérons pour vous encourager à nommer systématiquement vos variables principales dans tous les scripts AWS Glue ETL.

Étape 3. Extraire des données d'une source

Dans tout processus ETL, vous devez d'abord définir le jeu de données source que vous voulez modifier. Dans l'éditeur visuel AWS Glue Studio, vous fournissez ces informations en créant un nœud Source.

Au cours de cette étape, vous devez fournir à la méthode `create_dynamic_frame.from_catalog` une `database` et un `table_name` pour extraire des données d'une source configurée dans le catalogue de données AWS Glue.

À l'étape précédente, vous avez initialisé un objet `GlueContext`. Vous utilisez cet objet pour rechercher les méthodes qui sont utilisées pour configurer les sources, telles que `create_dynamic_frame.from_catalog`.

Dans cette procédure, vous écrivez le code suivant à l'aide de `create_dynamic_frame.from_catalog`. Ce code fait partie de l'exemple de script généré.

```
S3bucket_node1 = glueContext.create_dynamic_frame.from_catalog(  
    database="yyz-tickets", table_name="tickets", transformation_ctx="S3bucket_node1"  
)
```

Extraire des données d'une source

1. Consultez la documentation pour trouver une méthode permettant d'`GlueContext` extraire des données d'une source définie dans le AWS Glue Data Catalog. Ces méthodes sont documentées dans [the section called “GlueContext”](#). Choisissez la méthode [create_dynamic_frame.from_catalog](#). Appelez cette méthode sur `glueContext`.

2. Consultez la documentation pour `create_dynamic_frame.from_catalog`. Cette méthode nécessite les paramètres `database` et `table_name`. Fournissez les paramètres nécessaires à `create_dynamic_frame.from_catalog`.

Le catalogue de données AWS Glue stocke des informations sur l'emplacement et le format de vos données sources. Il a été configuré dans la section des prérequis. Vous n'avez pas besoin de fournir ces informations directement à votre script.

3. Facultatif – fournissez le paramètre `transformation_ctx` à la méthode afin de prendre en charge les signets de tâche. Vous pouvez en savoir plus sur les signets de tâche dans la section suivante, [the section called “Facultatif : activer les signets de tâche”](#).

Note

Méthodes courantes d'extraction de données

[the section called “create_dynamic_frame_from_catalog”](#) est utilisé pour se connecter aux tables du catalogue de données AWS Glue.

Si vous devez fournir directement à votre tâche une configuration qui décrit la structure et l'emplacement de votre source, consultez la méthode [the section called “create_dynamic_frame_from_options”](#). Vous devrez fournir des paramètres plus détaillés décrivant vos données que lorsque vous utilisez `create_dynamic_frame.from_catalog`.

Reportez-vous à la documentation supplémentaire sur `format_options` et `connection_parameters` pour identifier les paramètres requis. Pour savoir comment fournir à votre script des informations concernant le format de vos données sources, consultez [the section called “Options de format de données”](#). Pour savoir comment fournir à votre script des informations concernant l'emplacement de vos données sources, consultez [the section called “Paramètres de connexion”](#).

Si vous lisez des informations provenant d'une source de streaming, vous fournissez des informations sources à votre tâche via les méthodes [the section called “create_data_frame_from_catalog”](#) ou [the section called “create_data_frame_from_options”](#).

Notez que ces méthodes renvoient Apache Spark DataFrames.

Notre code généré appelle `create_dynamic_frame.from_catalog`, tandis que la documentation de référence fait référence à `create_dynamic_frame_from_catalog`. Ces méthodes appellent finalement le même code et sont incluses afin que vous puissiez écrire du code plus propre. Vous pouvez le vérifier en consultant le code source de notre wrapper Python, disponible sur [aws-glue-lib](#).

Étape 4 : Transformation de données avec AWS Glue

Après avoir extrait les données sources dans un processus ETL, vous devez décrire la manière dont vous souhaitez modifier vos données. Vous fournissez ces informations en créant un nœud Transform dans l'éditeur visuel AWS Glue Studio.

À cette étape, fournissez la méthode `ApplyMapping` avec une carte des noms et des types de champs actuels et souhaités pour transformer votre `DynamicFrame`.

Vous effectuez les transformations suivantes.

- Supprimez les quatre clés `location` et `province`.
- Modifiez le nom de `officer` en `officer_name`.
- Modifiez le type de `ticket_number` et `set_fine_amount` en `float`.

`create_dynamic_frame.from_catalog` vous fournit un objet `DynamicFrame`. A `DynamicFrame` représente un ensemble de données dans AWS Glue. AWS Les transformations à la colle sont des opérations qui changent `DynamicFrames`.

Note

Qu'est-ce qu'un `DynamicFrame` ?

Un `DynamicFrame` est une abstraction qui vous permet de connecter un jeu de données à une description des noms et types d'entrées dans les données. Dans Apache Spark, il existe une abstraction similaire appelée `DataFrame`. Pour une explication `DataFrames`, consultez le [guide Spark SQL](#).

Avec `DynamicFrames`, vous pouvez décrire les schémas de jeux de données de manière dynamique. Prenons l'exemple d'un ensemble de données avec une colonne de prix, où certaines entrées stockent le prix sous forme de chaîne, tandis que d'autres le stockent sous forme de double. AWS Glue calcule un schéma on-the-fly : elle crée un enregistrement autodescriptif pour chaque ligne.

Les champs incohérents (comme le prix) sont explicitement représentés par un type (`ChoiceType`) dans le schéma du cadre. Vous pouvez corriger vos champs incohérents en les supprimant avec `DropFields` ou en les résolvant avec `ResolveChoice`. Il s'agit de transformations disponibles sur le `DynamicFrame`. Vous pouvez ensuite réécrire vos données dans votre lac de données avec `writeDynamicFrame`.

Vous pouvez appeler un grand nombre des mêmes transformations à partir des méthodes sur la classe `DynamicFrame`, ce qui peut conduire à des scripts plus lisibles. Pour plus d'informations sur `DynamicFrame`, consultez [the section called “DynamicFrame”](#).

Dans cette procédure, vous écrivez le code suivant à l'aide de `ApplyMapping`. Ce code fait partie de l'exemple de script généré.

```
ApplyMapping_node2 = ApplyMapping.apply(  
    frame=S3bucket_node1,  
    mappings=[  
        ("tag_number_masked", "string", "tag_number_masked", "string"),  
        ("date_of_infraction", "string", "date_of_infraction", "string"),  
        ("ticket_date", "string", "ticket_date", "string"),  
        ("ticket_number", "decimal", "ticket_number", "float"),  
        ("officer", "decimal", "officer_name", "decimal"),  
        ("infraction_code", "decimal", "infraction_code", "decimal"),  
        ("infraction_description", "string", "infraction_description", "string"),  
        ("set_fine_amount", "decimal", "set_fine_amount", "float"),  
        ("time_of_infraction", "decimal", "time_of_infraction", "decimal"),  
    ],  
    transformation_ctx="ApplyMapping_node2",  
)
```

Pour transformer les données avec AWS Glue

1. Consultez la documentation pour identifier une transformation permettant de modifier et de supprimer des champs. Pour en savoir plus, consultez [the section called “GlueTransform”](#). Choisissez la transformation `ApplyMapping`. Pour plus d'informations sur `ApplyMapping`, consultez [the section called “ApplyMapping”](#). Appelez `apply` sur l'objet de transformation `ApplyMapping`.

Note

Qu'est-ce qu'`ApplyMapping` ?

`ApplyMapping` prend un `DynamicFrame` et le transforme. Il prend une liste de tuples qui représentent des transformations sur des champs – un « mappage ». Les deux premiers éléments du tuple, un nom et un type de champ, sont utilisés pour identifier un champ du cadre. Les deux autres paramètres sont également un nom et un type de champ.

ApplyMapping convertit le champ source en nom cible et saisissez-en un nouveauDynamicFrame, qu'il renvoie. Les champs qui ne sont pas fournis sont supprimés dans la valeur de retour.

Plutôt que d'appeler apply, vous pouvez appeler la même transformation avec la méthode apply_mapping sur le DynamicFrame, pour créer un code plus fluide et lisible. Pour de plus amples informations, veuillez consulter [the section called “apply_mapping”](#).

2. Consultez la documentation pour ApplyMapping afin d'identifier les paramètres requis. Consultez [the section called “ApplyMapping”](#). Vous constaterez que cette méthode nécessite les paramètres frame et mappings. Fournissez les paramètres nécessaires à ApplyMapping.
3. Facultatif – fournissez transformation_ctx à la méthode afin de prendre en charge les signets de tâche. Vous pouvez en savoir plus sur les signets de tâche dans la section suivante, [the section called “Facultatif : activer les signets de tâche”](#).

Note

Fonctionnalité Apache Spark

Nous proposons des transformations pour rationaliser les flux de travail ETL au sein de votre tâche. Vous avez également accès aux bibliothèques qui sont disponibles dans un programme Spark de votre tâche, conçues à des fins plus générales. Pour les utiliser, vous effectuez une conversion entre DynamicFrame et DataFrame.

Vous pouvez créer un DataFrame avec [the section called “toDF”](#). Vous pouvez ensuite utiliser les méthodes disponibles sur le DataFrame pour transformer votre ensemble de données. Pour plus d'informations sur ces méthodes, consultez [DataFrame](#). Vous pouvez ensuite effectuer une conversion à [the section called “fromDF”](#) envers en utilisant les opérations AWS Glue pour charger votre cadre sur une cible.

Étape 5. Charger des données dans une cible

Après avoir transformé vos données, vous les stockez généralement dans un endroit différent de la source. Vous effectuez cette opération en créant un nœud cible dans l'éditeur visuel AWS Glue Studio.

Au cours de cette étape, vous fournissez à la méthode des valeurs `write_dynamic_frame.from_options`, `connection_type`, `connection_options`, `format` et `format_options` pour charger des données dans un compartiment cible dans Amazon S3.

À l'étape 1, vous avez initialisé un objet `GlueContext`. Dans AWS Glue, vous trouverez ici les méthodes utilisées pour configurer les cibles, un peu comme les sources.

Dans cette procédure, vous écrivez le code suivant à l'aide de `write_dynamic_frame.from_options`. Ce code fait partie de l'exemple de script généré.

```
S3bucket_node3 = glueContext.write_dynamic_frame.from_options(  
    frame=ApplyMapping_node2,  
    connection_type="s3",  
    format="glueparquet",  
    connection_options={"path": "s3://amzn-s3-demo-bucket", "partitionKeys": []},  
    format_options={"compression": "gzip"},  
    transformation_ctx="S3bucket_node3",  
)
```

Charger des données dans une cible

1. Consultez la documentation pour trouver une méthode pour charger des données dans un compartiment Amazon S3 cible. Ces méthodes sont documentées dans [the section called “GlueContext”](#). Choisissez la méthode [the section called “write_dynamic_frame_from_options”](#). Appelez cette méthode sur `glueContext`.

Note

Méthodes courantes pour le chargement de données

`write_dynamic_frame.from_options` est la méthode la plus courante pour charger des données. Il prend en charge toutes les cibles disponibles dans AWS Glue.

Si vous écrivez sur une cible JDBC définie dans une connexion AWS Glue, utilisez cette méthode. [the section called “write_dynamic_frame_from_jdbc_conf”](#)

AWS Les connexions Glue stockent des informations sur la manière de se connecter à une source de données. Il n'est donc plus nécessaire de fournir ces informations dans `connection_options`. Cependant, vous devez toujours utiliser `connection_options` pour fournir `dbtable`.

`write_dynamic_frame.from_catalog` n'est pas une méthode courante pour charger des données. Cette méthode met à jour le catalogue de données AWS Glue

sans mettre à jour le jeu de données sous-jacent et est utilisée en combinaison avec d'autres processus qui modifient le jeu de données sous-jacent. Pour de plus amples informations, veuillez consulter [the section called “Mise à jour du schéma et ajout de nouvelles partitions”](#).

2. Consultez la documentation pour [the section called “write_dynamic_frame_from_options”](#). Cette méthode nécessite `frame`, `connection_type`, `format`, `connection_options` et `format_options`. Appelez cette méthode sur `glueContext`.
 - a. Reportez-vous à la documentation supplémentaire sur `format_options` et `format` pour identifier les paramètres dont vous avez besoin. Pour une explication des formats de données, consultez [the section called “Options de format de données”](#).
 - b. Reportez-vous à la documentation supplémentaire sur `connection_type` et `connection_options` pour identifier les paramètres dont vous avez besoin. Pour une explication des connexions, consultez [the section called “Paramètres de connexion”](#).
 - c. Fournissez les paramètres nécessaires à `write_dynamic_frame.from_options`. Cette méthode a une configuration similaire à `create_dynamic_frame.from_options`.
3. Facultatif – fournissez `transformation_ctx` à `write_dynamic_frame.from_options` afin de prendre en charge les signets de tâche. Vous pouvez en savoir plus sur les signets de tâche dans la section suivante, [the section called “Facultatif : activer les signets de tâche”](#).

Étape 6. Valider l'objet **Job**

À l'étape 1, vous avez initialisé un objet `Job`. Vous devrez peut-être terminer manuellement son cycle de vie à la fin de votre script si certaines fonctionnalités facultatives en ont besoin pour fonctionner correctement, par exemple lors de l'utilisation de Job Bookmarks. Ce travail est réalisé dans les coulisses de AWS Glue Studio.

Dans cette étape, appelez la méthode `commit` sur l'objet `Job`.

Dans cette procédure, vous écrivez le code suivant. Ce code fait partie de l'exemple de script généré.

```
job.commit()
```

Pour valider l'objet **Job**

1. Si vous ne l'avez pas encore fait, suivez les étapes facultatives décrites dans les sections précédentes pour inclure `transformation_ctx`.

2. Appelez `commit`.

Facultatif : activer les signets de tâche

À chaque étape précédente, il vous a été demandé de définir les paramètres `transformation_ctx`. Ceci est lié à une fonctionnalité appelée signets de tâche.

Avec les signets de tâche, vous pouvez gagner du temps et de l'argent grâce à des tâches qui s'exécutent de manière récurrente, par rapport à des jeux de données où il est possible de suivre facilement le travail précédent. Les signets de tâches suivent la progression d'une transformation AWS Glue dans un ensemble de données par rapport aux exécutions précédentes. En suivant la fin des séries précédentes, AWS Glue peut limiter son travail aux lignes qu'elle n'a jamais traitées auparavant. Pour plus d'informations sur les signets de tâche, consultez [the section called “Suivi des données traitées à l'aide de signets de tâche”](#).

Pour activer les favoris des signets de tâche, ajoutez d'abord le `transformation_ctx` des déclarations sur les fonctions que nous fournissons, comme illustré dans les exemples précédents. L'état du signet de tâche est conservé au fil des exécutions. Les paramètres `transformation_ctx` sont des clés utilisées pour accéder à cet état. Seules, ces instructions ne servent à rien. Vous devez également activer la fonctionnalité dans la configuration de votre tâche.

Au cours de cette procédure, vous activez les signets de tâche à l'aide de la AWS Management Console.

Définir les signets de tâche

1. Accédez à la section Détails de la tâche de votre tâche correspondante.
2. Définissez Job bookmark (Signet de tâche) sur Enable (Activer).

Étape 7. Exécution de votre code en tant que tâche

Dans cette étape, vous exécutez votre tâche pour vérifier que vous avez bien suivi ce didacticiel. Cela se fait en cliquant sur un bouton, comme dans l'éditeur visuel AWS Glue Studio.

Exécuter votre code en tant que tâche

1. Choisissez Untitled job (Tâche sans titre) dans la barre de titre pour modifier et définir le nom de votre tâche.

2. Accédez à l'onglet Job details (Détails de la tâche). Attribuez à votre tâche un rôle IAM. Vous pouvez utiliser celui créé par le AWS CloudFormation modèle dans les prérequis du didacticiel AWS Glue Studio. Si vous avez terminé ce didacticiel, il devrait être disponible sous AWS Glue StudioRole.
3. Choisissez Save (Enregistrer) pour enregistrer votre script.
4. Choisissez Run (Exécuter) pour exécuter votre tâche.
5. Accédez à l'onglet Runs (Exécutions) pour vérifier que votre tâche est terminée.
6. Naviguez vers `amzn-s3-demo-bucket`, la cible pour `write_dynamic_frame.from_options`. Vérifiez que le résultat correspond à vos attentes.

Pour plus d'informations sur la configuration et la gestion des tâches, consultez [the section called “Fournir vos propres scripts personnalisés”](#).

En savoir plus

Les bibliothèques et méthodes Apache Spark sont disponibles dans les scripts AWS Glue. Vous pouvez consulter la documentation Spark pour comprendre ce que vous pouvez faire avec les bibliothèques incluses. Pour de plus amples informations, consultez la [section des exemples du référentiel Spark source](#).

AWS Glue 2.0+ inclut plusieurs bibliothèques Python courantes par défaut. Il existe également des mécanismes pour charger vos propres dépendances dans une tâche AWS Glue dans un environnement Scala ou Python. Pour plus d'informations sur les dépendances Python, consultez [the section called “Bibliothèques Python”](#).

Pour plus d'exemples d'utilisation des fonctionnalités de AWS Glue en Python, consultez [the section called “Exemples Python”](#). Les tâches Scala et Python ont des fonctionnalités identiques, donc nos exemples Python devraient vous donner quelques idées sur la façon d'effectuer une tâche similaire dans Scala.

Programmez les scripts ETL AWS Glue dans PySpark

Vous pouvez trouver des exemples de code Python et des utilitaires pour AWS Glue dans le [référentiel d'échantillons AWS Glue](#) sur le GitHub site Web.

Utiliser Python avec AWS Glue

AWS Glue prend en charge une extension du dialecte PySpark Python pour les tâches d'extraction, de transformation et de chargement (ETL) par script. Cette section décrit comment utiliser Python dans les scripts ETL et avec l'API AWS Glue.

- [Configuration pour utiliser Python avec AWS Glue](#)
- [Appel AWS Glue APIs en Python](#)
- [Utiliser les bibliothèques Python avec AWS Glue](#)
- [AWS Glue Exemples de code Python](#)

AWS PySpark Extensions Glue

AWS Glue a créé les extensions suivantes pour le dialecte PySpark Python.

- [Accès aux paramètres à l'aide de `getResolvedOptions`](#)
- [PySpark types d'extensions](#)
- [DynamicFrame classe](#)
- [DynamicFrameCollection classe](#)
- [DynamicFrameWriter classe](#)
- [DynamicFrameReader classe](#)
- [GlueContext classe](#)

AWS Glue PySpark transforme

AWS Glue a créé les classes de transformation suivantes à utiliser dans les opérations PySpark ETL.

- [GlueTransform classe de base](#)
- [ApplyMapping classe](#)
- [DropFields classe](#)
- [DropNullFields classe](#)
- [ErrorsAsDynamicFrame classe](#)
- [FillMissingValues classe](#)

- [Classe Filter](#)
- [FindIncrementalMatches classe](#)
- [FindMatches classe](#)
- [FlatMap classe](#)
- [Classe Join](#)
- [Classe Map](#)
- [MapToCollection classe](#)
- [mergeDynamicFrame](#)
- [Classe Relationalize](#)
- [RenameField classe](#)
- [ResolveChoice classe](#)
- [SelectFields classe](#)
- [SelectFromCollection classe](#)
- [Classe Spigot](#)
- [SplitFields classe](#)
- [SplitRows classe](#)
- [Classe Unbox](#)
- [UnnestFrame classe](#)

Configuration pour utiliser Python avec AWS Glue

Utilisez Python pour développer vos scripts ETL pour les tâches Spark. Les versions de Python prises en charge pour les tâches ETL dépendent du AWS Glue version du job. Pour plus d'informations sur AWS Glue versions, voir le [Glue version job property](#).

Pour configurer votre système afin d'utiliser Python avec AWS Glue

Procédez comme suit pour installer Python et pour pouvoir invoquer le AWS Glue APIs.

1. Si vous n'avez pas déjà Python installé, téléchargez et installez-le [à partir de la page de téléchargement Python.org](#).
2. Installez le AWS Command Line Interface (AWS CLI) comme indiqué dans la [documentation de la AWS CLI](#).

Le n' AWS CLI est pas directement nécessaire pour utiliser Python. Cependant, son installation et sa configuration constituent un moyen pratique de le configurer à l' AWS aide des informations d'identification de votre compte et de vérifier qu'elles fonctionnent.

3. Installez le AWS SDK pour Python (Boto 3), comme indiqué dans le guide de démarrage rapide de [Boto3](#).

Les ressources Boto 3 ne APIs sont pas encore disponibles pour AWS Glue. Actuellement, seul le client Boto 3 APIs peut être utilisé.

Pour en savoir plus sur Boto 3, consultez [Mise en route du kit SDK AWS for Python \(Boto3\)](#).

Vous pouvez trouver des exemples de code Python et des utilitaires pour AWS Glue dans le [AWS Glue référentiel d'échantillons](#) sur le GitHub site Web.

Appel AWS Glue APIs en Python

Notez que les ressources Boto 3 ne APIs sont pas encore disponibles pour AWS Glue. Actuellement, seul le client Boto 3 APIs peut être utilisé.

AWS Glue Noms d'API en Python

AWS Les noms des API Glue en Java et dans d'autres langages de programmation sont généralement CamelCased. Cependant, lors d'un appel à partir de Python, ces noms génériques sont modifiés en minuscules, avec les différentes parties du nom séparées par des traits de soulignement afin de les rendre plus proches du langage Python. Dans la documentation de [AWS Glue API](#) référence, ces noms pythoniques sont listés entre parenthèses après les noms génériques CamelCased .

Cependant, bien que le AWS Glue Les noms d'API eux-mêmes sont transformés en minuscules, leurs noms de paramètres restent en majuscules. Il est important de s'en souvenir, car les paramètres doivent être transmis par leur nom lors de l'appel AWS Glue APIs, comme décrit dans la section suivante.

Transmission et accès aux paramètres Python dans AWS Glue

En Python, les appels à AWS Glue APIs, il est préférable de passer les paramètres explicitement par leur nom. Par exemple :

```
job = glue.create_job(Name='sample', Role='Glue_DefaultRole',
```

```
Command={'Name': 'glueetl',
        'ScriptLocation': 's3://my_script_bucket/scripts/
my_etl_script.py'}}
```

Il est utile de comprendre que Python crée un dictionnaire de tuples nom/valeur que vous spécifiez comme arguments de script ETL d'un [Structure Job](#) ou [JobRun structure](#). Boto 3 les transmet ensuite à AWS Glue au format JSON via un appel d'API REST. Cela signifie que vous ne pouvez pas vous fier à l'ordre des arguments lorsque vous y accédez dans votre script.

Par exemple, supposons que vous lanciez un JobRun dans un gestionnaire Lambda Python, et que vous souhaitiez spécifier plusieurs paramètres. Votre code peut alors se présenter comme suit :

```
from datetime import datetime, timedelta

client = boto3.client('glue')

def lambda_handler(event, context):
    last_hour_date_time = datetime.now() - timedelta(hours = 1)
    day_partition_value = last_hour_date_time.strftime("%Y-%m-%d")
    hour_partition_value = last_hour_date_time.strftime("%-H")

    response = client.start_job_run(
        JobName = 'my_test_job',
        Arguments = {
            '--day_partition_key': 'partition_0',
            '--hour_partition_key': 'partition_1',
            '--day_partition_value': day_partition_value,
            '--hour_partition_value': hour_partition_value } )
```

Pour accéder à ces paramètres de manière fiable dans votre script ETL, spécifiez-les par leur nom en utilisant AWS Glue, `getResolvedOptions` puis accédez-y à partir du dictionnaire obtenu :

```
import sys
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv,
                          ['JOB_NAME',
                          'day_partition_key',
                          'hour_partition_key',
                          'day_partition_value',
                          'hour_partition_value'])
print "The day partition key is: ", args['day_partition_key']
```

```
print "and the day partition value is: ", args['day_partition_value']
```

Si vous souhaitez transmettre un argument qui est une chaîne JSON imbriquée, afin de préserver la valeur du paramètre telle qu'elle est transmise à votre AWS Glue Job ETL, vous devez encoder la chaîne de paramètres avant de démarrer l'exécution du travail, puis décoder la chaîne de paramètres avant de la référencer dans votre script de travail. Prenons l'exemple de la chaîne d'arguments suivante :

```
glue_client.start_job_run(JobName = "gluejobname", Arguments={
"--my_curly_braces_string": '{"a": {"b": {"c": [{"d": {"e": 42}}]}}}'
})
```

Pour transférer ce paramètre correctement, vous devez coder l'argument sous la forme d'une chaîne codée en Base64.

```
import base64
...
sample_string='{"a": {"b": {"c": [{"d": {"e": 42}}]}}'
sample_string_bytes = sample_string.encode("ascii")

base64_bytes = base64.b64encode(sample_string_bytes)
base64_string = base64_bytes.decode("ascii")
...
glue_client.start_job_run(JobName = "gluejobname", Arguments={
"--my_curly_braces_string": base64_bytes})
...
sample_string_bytes = base64.b64decode(base64_bytes)
sample_string = sample_string_bytes.decode("ascii")
print(f"Decoded string: {sample_string}")
...
```

Exemple : Créer et exécuter une tâche

L'exemple suivant montre comment appeler le AWS Glue API en utilisant Python, pour créer et exécuter une tâche ETL.

Pour créer et exécuter une tâche

1. Créez une instance de AWS Glue client :

```
import boto3
```

```
glue = boto3.client(service_name='glue', region_name='us-east-1',
                    endpoint_url='https://glue.us-east-1.amazonaws.com')
```

2. Crée une tâche. Vous devez utiliser `glueetl` comme nom de la commande ETL, comme indiqué dans le code suivant :

```
myJob = glue.create_job(Name='sample', Role='Glue_DefaultRole',
                        Command={'Name': 'glueetl',
                                'ScriptLocation': 's3://my_script_bucket/
scripts/my_etl_script.py'})
```

3. Démarrez une nouvelle exécution de la tâche que vous avez créée dans l'étape précédente :

```
myNewJobRun = glue.start_job_run(JobName=myJob['Name'])
```

4. Obtenez l'état de la tâche :

```
status = glue.get_job_run(JobName=myJob['Name'], RunId=myNewJobRun['JobRunId'])
```

5. Affichez l'état actuel de l'exécution de la tâche :

```
print(status['JobRun']['JobRunState'])
```

Utiliser les bibliothèques Python avec AWS Glue

AWS Glue vous permet d'installer des modules et bibliothèques Python supplémentaires à utiliser avec AWS Glue ETL.

Rubriques

- [Installation de bibliothèques Python supplémentaires dans AWS Glue 5.0 à l'aide de requirements.txt](#)
- [Installation de modules Python supplémentaires avec pip dans AWS Glue 2.0 ou version ultérieure](#)
- [Y compris des fichiers Python dotés de fonctionnalités PySpark natives](#)
- [Scripts de programmation utilisant des transformations visuelles](#)
- [Modules Python déjà fournis dans AWS Glue](#)
- [Compression de bibliothèques pour intégration](#)
- [Chargement de bibliothèques Python dans les blocs-notes AWS Glue Studio](#)

- [Chargement des bibliothèques Python dans un point de terminaison de développement](#)
- [Utilisation de bibliothèques Python dans une tâche ou JobRun](#)

Installation de bibliothèques Python supplémentaires dans AWS Glue 5.0 à l'aide de requirements.txt

Dans AWS Glue 5.0, vous pouvez fournir le standard de facto pour requirements.txt gérer les dépendances des bibliothèques Python. Pour ce faire, fournissez les deux paramètres de tâche suivants :

- Clé : `--python-modules-installer-option`

Valeur : `-r`

- Clé : `--additional-python-modules`

Valeur : `s3://path_to_requirements.txt`

AWS Les nœuds Glue 5.0 chargent initialement les bibliothèques python spécifiées dans requirements.txt. Voici un exemple de fichier requirements.txt :

```
awsranger==3.9.1
elasticsearch==8.15.1
PyAthena==3.9.0
PyMySQL==1.1.1
PyYAML==6.0.2
pyodbc==5.2.0
pyorc==0.9.0
redshift-connector==2.1.3
scipy==1.14.1
scikit-learn==1.5.2
SQLAlchemy==2.0.36
```

Installation de modules Python supplémentaires avec pip dans AWS Glue 2.0 ou version ultérieure

AWS Glue utilise le Python Package Installer (pip3) pour installer des modules supplémentaires qui seront utilisés par AWS Glue ETL. Vous pouvez utiliser le paramètre `--additional-python-modules` avec une liste de modules Python séparés par des virgules pour ajouter un nouveau module ou modifier la version d'un module existant. Vous pouvez installer des distributions personnalisées d'une bibliothèque en chargeant la distribution sur Amazon S3, puis en incluant le chemin d'accès à l'objet Amazon S3 dans votre liste de modules.

Vous pouvez transmettre des options supplémentaires à pip3 à l'aide du paramètre `--python-modules-installer-option`. Par exemple, vous pouvez transmettre `--upgrade` pour mettre à niveau les packages spécifiés par `--additional-python-modules`. Pour plus d'exemples, voir [Création de modules Python à partir d'une roue pour les charges de travail Spark ETL à l'aide de AWS Glue 2.0](#).

Si vos dépendances Python dépendent de manière transitive d'un code natif compilé, vous risquez de vous heurter à la limitation suivante : AWS Glue ne prend pas en charge la compilation de code natif dans l'environnement de travail. Cependant, les tâches AWS Glue s'exécutent dans un environnement Amazon Linux 2. Vous pouvez peut-être fournir vos dépendances natives sous une forme compilée via un élément distribuable Wheel.

Par exemple, pour mettre à jour ou ajouter un nouveau module `scikit-learn`, utilisez la clé/valeur suivante : `--additional-python-modules, "scikit-learn==0.21.3"`.

En outre, l'option `--additional-python-modules` vous permet de spécifier un chemin d'accès Amazon S3 vers un module de roue Python. Par exemple :

```
--additional-python-modules s3://aws-glue-native-spark/tests/j4.2/ephem-3.7.7.1-cp37-cp37m-linux_x86_64.whl,s3://aws-glue-native-spark/tests/j4.2/fbprophet-0.6-py3-none-any.whl,scikit-learn==0.21.3
```

Vous le spécifiez `--additional-python-modules` dans le champ Paramètres du job de la console AWS Glue ou en modifiant les arguments du job dans le AWS SDK. Pour de plus amples informations sur la définition des paramètres de la tâche, consultez [the section called “Paramètres des tâches”](#).

Y compris des fichiers Python dotés de fonctionnalités PySpark natives

AWS Glue utilise PySpark pour inclure des fichiers Python dans les tâches AWS Glue ETL. Vous aurez envie d'utiliser `--additional-python-modules` pour gérer vos dépendances lorsqu'elles sont disponibles. Vous pouvez utiliser le paramètre de tâche `--extra-py-files` pour inclure des fichiers Python. Les dépendances doivent être hébergées dans Amazon S3, et la valeur de l'argument doit être une liste de chemins non-espacés Amazon S3 délimités par des virgules. Cette fonctionnalité se comporte comme la gestion des dépendances Python que vous utiliseriez avec Spark. Pour plus d'informations sur la gestion des dépendances Python dans Spark, consultez la page [Utilisation des fonctionnalités PySpark natives](#) dans la documentation d'Apache Spark. `--extra-py-files` est utile dans les cas où votre code supplémentaire n'est pas empaqueté ou lorsque vous migrez un programme Spark avec une chaîne d'outils existante pour gérer les

dépendances. Pour que vos outils de dépendance soient gérables, vous devez regrouper vos dépendances avant de les soumettre.

Scripts de programmation utilisant des transformations visuelles

Lorsque vous créez une tâche AWS Glue à l'aide de l'interface visuelle de AWS Glue Studio, vous pouvez transformer vos données à l'aide de nœuds de transformation de données gérés et de transformations visuelles personnalisées. Pour plus d'informations sur les nœuds de transformation de données gérés, consultez [the section called “Transformez les données avec AWS Glue transformations gérées”](#). Pour plus d'informations sur les transformations visuelles personnalisées, consultez [the section called “ Transformez les données grâce à des transformations visuelles personnalisées ”](#). Les scripts utilisant des transformations visuelles ne peuvent être générés que lorsque le langage de votre travail est configuré pour utiliser Python.

Lors de la génération d'une tâche AWS Glue à l'aide de transformations visuelles, AWS Glue Studio inclut ces transformations dans l'environnement d'exécution en utilisant le `--extra-py-files` paramètre de configuration de la tâche. Pour de plus amples informations sur la définition des paramètres de la tâche, consultez [the section called “Paramètres des tâches”](#). Lorsque vous apportez des modifications à un script généré ou à un environnement d'exécution, vous devez conserver cette configuration de tâche pour que votre script s'exécute correctement.

Modules Python déjà fournis dans AWS Glue

Pour modifier la version de ces modules fournis, fournissez de nouvelles versions avec le paramètre de tâche `--additional-python-modules`.

AWS Glue version 5.0

AWS La version 5.0 de Glue inclut les modules Python suivants prêts à l'emploi :

- aiobotocore==2.13.1
- aiohappyhalls==2.3.5
- aiohttp==3.10.1
- aioitertools==0.11.0
- aiosignal==1.3.1
- appdirs==1.4.4
- attrs = 24,2,0
- boto3==1.34.131

- `botocore==1,34,131`
- `certifi==2024.7.4`
- `normaliseur de jeux de caractères ==3.3.2`
- `contourpy==1.2.1`
- `cycleur ==0,12.1`
- `fonttools==4.53.1`
- `liste congelée ==1.4.1`
- `fsspec==2024.6.1`
- `idna==2.10`
- `jmespath==0.10.0`
- `kaleido==0,2.1`
- `kiwisolver ==1.4.5`
- `matplotlib==3.9.0`
- `multidict==6,0.5`
- `numpy==1,26,4`
- `emballage==24,1`
- `pandas==2.2.2`
- `oreiller ==10.4.0`
- `pip==22.3.1`
- `plotly=5.23.0`
- `pyarrow=17,0,0`
- `pyparsing==3.1.2`
- `python-dateutil==2.9.0.post0`
- `pytz=2024,1`
- `demandes ==2.32.2`
- `s3fs==2024,6,1`
- `transfert s3 ==0.10.2`
- `Seaborn = 0,13,2`
- `outils de configuration ==59.6.0`

- six==1.16.0
- ténacité ==9,0.0
- tzdata=2024,1
- urllib3==1.25.10
- virtualenv = 20.4.0
- wrapt==1,16,0
- yarl==1,9.4

AWS Glue version 4.0

AWS La version 4.0 de Glue inclut les modules Python suivants prêts à l'emploi :

- aiobotocore==2.4.1
- aiohttp==3.8.3
- aioitertools==0.11.0
- aiosignal==1.3.1
- async-timeout==4.0.2
- asyncctest==0.13.0
- attrs==22.2.0
- avro-python3==1.10.2
- boto3==1.24.70
- botocore==1.27.59
- certifi==2021.5.30
- chardet==3.0.4
- charset-normalizer==2.1.1
- click==8.1.3
- cycler==0.10.0
- Cython==0.29.32
- docutils==0.17.1
- enum34==1.1.10

- frozenlist==1.3.3
- fsspec==2021.8.1
- idna==2.10
- importlib-metadata==5.0.0
- jmespath==0.10.0
- joblib==1.0.1
- kaleido==0,2.1
- kiwisolver==1.4.4
- matplotlib==3.4.3
- mpmath==1.2.1
- multidict==6.0.4
- nltk==3.7
- numpy==1.23.5
- packaging==23.0
- pandas==1.5.1
- patsy==0.5.1
- Pillow==9.4.0
- pip==23.0.1
- plutly=5.16.0
- pmdarima==2.0.1
- ptvsd==4.3.2
- pyarrow==10.0.0
- pydevd==2.5.0
- pyhocon==0.3.58
- PyMySQL==1.0.2
- pyparsing==2.4.7
- python-dateutil==2.8.2
- pytz==2021.1
- PyYAML==6.0.1

- regex==2022.10.31
- requests==2.23.0
- s3fs==2022.11.0
- s3transfer==0.6.0
- scikit-learn==1.1.3
- scipy==1.9.3
- setuptools==49.1.3
- six==1.16.0
- statsmodels==0.13.5
- subprocess32==3.5.4
- sympy==1.8
- tbats==1.1.0
- threadpoolctl==3.1.0
- tqdm==4.64.1
- typing_extensions==4.4.0
- urllib3==1.25.11
- wheel==0.37.0
- wrapt==1.14.1
- yarl==1.8.2
- zipp==3.10.0

AWS Glue version 3.0

AWS La version 3.0 de Glue inclut les modules Python suivants prêts à l'emploi :,

- aiobotocore==1.4.2
- aiohttp==3.8.3
- aioitertools==0.11.0
- aiosignal==1.3.1
- async-timeout==4.0.2
- asyncctest==0.13.0

- attrs==22.2.0
- avro-python3==1.10.2
- boto3==1.18.50
- botocore==1.21.50
- certifi==2021.5.30
- chardet==3.0.4
- charset-normalizer==2.1.1
- click==8.1.3
- cycler==0.10.0
- Cython==0.29.4
- docutils==0.17.1
- enum34==1.1.10
- frozenlist==1.3.3
- fsspec==2021.8.1
- idna==2.10
- importlib-metadata==6.0.0
- jmespath==0.10.0
- joblib==1.0.1
- kiwisolver==1.3.2
- matplotlib==3.4.3
- mpmath==1.2.1
- multidict==6.0.4
- nltk==3.6.3
- numpy==1.19.5
- packaging==23.0
- pandas==1.3.2
- patsy==0.5.1
- Pillow==9.4.0
- pip==23.0

- pmdarima==1.8.2
- ptvsd==4.3.2
- pyarrow==5.0.0
- pydevd==2.5.0
- pyhocon==0.3.58
- PyMySQL==1.0.2
- pyparsing==2.4.7
- python-dateutil==2.8.2
- pytz==2021.1
- PyYAML==5.4.1
- regex==2022.10.31
- requests==2.23.0
- s3fs==2021.8.1
- s3transfer==0.5.0
- scikit-learn==0.24.2
- scipy==1.7.1
- six==1.16.0
- Spark==1.0
- statsmodels==0.12.2
- subprocess32==3.5.4
- sympy==1.8
- tbats==1.1.0
- threadpoolctl==3.1.0
- tqdm==4.64.1
- typing_extensions==4.4.0
- urllib3==1.25.11
- wheel==0.37.0
- wrapt==1.14.1
- yarl==1.8.2

- zipp==3.12.0

AWS Glue version 2.0

AWS La version 2.0 de Glue inclut les modules Python suivants prêts à l'emploi :

- avro-python3==1.10.0
- awscli==1.27.60
- boto3==1.12.4
- botocore==1.15.4
- certifi==2019.11.28
- chardet==3.0.4
- click==8.1.3
- colorama==0.4.4
- cycler==0.10.0
- Cython==0.29.15
- docutils==0.15.2
- enum34==1.1.9
- fsspec==0.6.2
- idna==2.9
- importlib-metadata==6.0.0
- jmespath==0.9.4
- joblib==0.14.1
- kiwisolver==1.1.0
- matplotlib==3.1.3
- mpmath==1.1.0
- nltk==3.5
- numpy==1.18.1
- pandas==1.0.1
- patsy==0.5.1
- pmdarima==1.5.3

- ptvsd==4.3.2
- pyarrow==0.16.0
- pyasn1==0.4.8
- pydevd==1.9.0
- pyhocon==0.3.54
- PyMySQL==0.9.3
- pyparsing==2.4.6
- python-dateutil==2.8.1
- pytz==2019.3
- PyYAML==5.3.1
- regex==2022.10.31
- requests==2.23.0
- rsa==4.7.2
- s3fs==0.4.0
- s3transfer==0.3.3
- scikit-learn==0.22.1
- scipy==1.4.1
- setuptools==45.2.0
- six==1.14.0
- Spark==1.0
- statsmodels==0.11.1
- subprocess32==3.5.4
- sympy==1.5.1
- tbats==1.0.9
- tqdm==4.64.1
- typing-extensions==4.4.0
- urllib3==1.25.8
- wheel==0.35.1
- zipp==3.12.0

Compression de bibliothèques pour intégration

Sauf si elle est comprise dans un seul fichier `.py`, une bibliothèque doit être packagée dans une archive `.zip`. Le répertoire du package doit être à la racine de l'archive et contenir un fichier `__init__.py` pour le package. Python sera alors en mesure d'importer le package normalement.

Si votre bibliothèque se compose d'un seul module Python dans un fichier `.py`, vous n'avez pas besoin de la mettre dans un fichier `.zip`.

Chargement de bibliothèques Python dans les blocs-notes AWS Glue Studio

Pour spécifier les bibliothèques Python dans les blocs-notes AWS Glue Studio, consultez la section [Installation de modules Python supplémentaires](#).

Chargement des bibliothèques Python dans un point de terminaison de développement

Si vous utilisez différents ensembles de bibliothèques pour différents scripts ETL, vous pouvez configurer un point de terminaison de développement distinct pour chaque ensemble, ou écraser le(s) fichier(s) `.zip` de bibliothèque que votre point de terminaison de développement charge à chaque fois que vous basculez d'un script à un autre.

Vous pouvez utiliser la console pour spécifier un ou plusieurs fichiers `.zip` de bibliothèque pour un point de terminaison de développement lorsque vous créez celui-ci. Après avoir attribué un nom et un rôle IAM, sélectionnez Script Libraries and job parameters (optional) (Bibliothèques de scripts et paramètres de tâches [facultatif]) et saisissez le chemin d'accès Amazon S3 complet à votre fichier `.zip` de bibliothèque dans la zone Python library path (Chemin de bibliothèque Python). Par exemple :

```
s3://bucket/prefix/site-packages.zip
```

Si vous le souhaitez, vous pouvez spécifier plusieurs chemins complets pour les fichiers, en les séparant par des virgules, mais sans espace, comme l'exemple suivant :

```
s3://bucket/prefix/lib_A.zip,s3://bucket_B/prefix/lib_X.zip
```

Si vous mettez à jour ces fichiers `.zip` ultérieurement, vous pouvez utiliser la console pour les importer de nouveau dans votre point de terminaison de développement. Naviguez vers le point de terminaison de développement concerné, cochez la case située en regard, puis choisissez Update ETL libraries (Mettre à jour des bibliothèques ETL) dans le menu Action.

De la même manière, vous pouvez spécifier des fichiers de bibliothèque à l'aide de la AWS Glue APIs. Lorsque vous créez un point de terminaison de développement en appelant [CreateDevEndpoint action \(Python : create_dev_endpoint\)](#), vous pouvez spécifier un ou plusieurs chemins complets de bibliothèques dans le paramètre `ExtraPythonLibsS3Path`, dans un appel ressemblant à ceci :

```
dep = glue.create_dev_endpoint(
    EndpointName="testDevEndpoint",
    RoleArn="arn:aws:iam::123456789012",
    SecurityGroupIds="sg-7f5ad1ff",
    SubnetId="subnet-c12fdb4",
    PublicKey="ssh-rsa AAAAB3NzaC1yc2EAAAADAQABAAQCTp04H/y...",
    NumberOfNodes=3,
    ExtraPythonLibsS3Path="s3://bucket/prefix/lib_A.zip,s3://bucket_B/prefix/
lib_X.zip")
```

Lorsque vous mettez à jour un point de terminaison de développement, vous pouvez également mettre à jour les bibliothèques chargées par ce point de terminaison en utilisant un objet [DevEndpointCustomLibraries](#) et en définissant le paramètre `UpdateEtlLibraries` sur `True` lors de l'appel de [UpdateDevEndpoint \(update_dev_endpoint\)](#).

Utilisation de bibliothèques Python dans une tâche ou JobRun

Lorsque vous créez un objet Job sur la console, vous pouvez spécifier un ou plusieurs fichiers .zip de bibliothèque en sélectionnant Script Libraries and job parameters (optional) (Bibliothèques de scripts et paramètres de tâches [facultatif]) et en entrant le ou les chemins d'accès Amazon S3 complets aux bibliothèques, comme vous le feriez lors de la création d'un point de terminaison de développement :

```
s3://bucket/prefix/lib_A.zip,s3://bucket_B/prefix/lib_X.zip
```

Si vous appelez [CreateJob \(créer_job\)](#), vous pouvez spécifier un ou plusieurs chemins d'accès complets aux bibliothèques par défaut en utilisant les paramètres par défaut `--extra-py-files`, comme suit :

```
job = glue.create_job(Name='sampleJob',
    Role='Glue_DefaultRole',
    Command={'Name': 'glueetl',
        'ScriptLocation': 's3://my_script_bucket/scripts/
my_etl_script.py'},
```

```
DefaultArguments={'--extra-py-files': 's3://bucket/prefix/  
lib_A.zip,s3://bucket_B/prefix/lib_X.zip'})
```

Ensuite, lorsque vous démarrez une JobRun, vous pouvez remplacer le paramètre de bibliothèque par défaut par un autre :

```
runId = glue.start_job_run(JobName='sampleJob',  
                           Arguments={'--extra-py-files': 's3://bucket/prefix/  
lib_B.zip'})
```

AWS Glue Exemples de code Python

- [Exemple de code : Données de jonction et de mise en relation](#)
- [Exemple de code : préparation des données à l'aide ResolveChoice de Lambda et ApplyMapping](#)

Exemple de code : Données de jonction et de mise en relation

Cet exemple utilise un ensemble de données qui a été téléchargé sur <http://everypolitician.org/> dans le compartiment sample-dataset d'Amazon Simple Storage Service (Amazon S3) : s3://awsglue-datasets/examples/us-legislators/all. Cet ensemble de données contient des données au format JSON concernant les législateurs américains et les fonctions qu'ils ont occupées à la Chambre des représentants et au Sénat. Il a été légèrement modifié et il a été mis à la disposition des utilisateurs dans un compartiment Amazon S3 public aux fins de ce didacticiel.

Le code source de cet exemple se trouve dans le `join_and_relationalize.py` fichier du [AWS Glue référentiel d'échantillons](#) sur le GitHub site Web.

Grâce à ces données, ce didacticiel vous montre comment effectuer les opérations suivantes :

- Utilisez un AWS Glue crawler pour classer les objets stockés dans un compartiment Amazon S3 public et enregistrer leurs schémas dans le catalogue de données AWS Glue.
- Examiner les métadonnées et les schémas de la table résultant de l'analyse ;
- Écrire un script Extract-transform-load (ETL) en Python qui utilise les métadonnées dans Data Catalog pour effectuer les actions suivantes :
 - Joindre les données dans différents fichiers sources en une seule table de données (c'est-à-dire, dénormaliser les données).
 - Filtrer la table jointe en tables distinctes par type de législateur.

- Écrire les données résultantes en vue de séparer les fichiers Apache Parquet à des fins d'analyse ultérieure.

La méthode préférée pour déboguer Python ou PySpark des scripts pendant l'exécution AWS consiste à utiliser [Notebooks on AWS Glue Studio](#).

Étape 1 : analyser les données dans le compartiment Amazon S3

1. Connectez-vous au AWS Management Console, puis ouvrez le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. En suivant les étapes décrites [Configuration d'un crawler](#), créez un nouveau robot d'exploration capable d'explorer le `s3://awsglue-datasets/examples/us-legislators/all` jeu de données dans une base de données nommée `legislators` dans le catalogue de données AWS Glue. Les exemples de données sont déjà dans ce compartiment Amazon S3 public.
3. Exécutez le nouvel crawler, puis activez la base de données `legislators`.

L'crawler crée les tables de métadonnées suivantes :

- `persons_json`
- `memberships_json`
- `organizations_json`
- `events_json`
- `areas_json`
- `countries_r_json`

Il s'agit d'un ensemble de tables semi-normalisé contenant les législateurs et leurs carrières.

Étape 2 : Ajouter le script Boilerplate au bloc-notes de point de terminaison de développement

Collez le script standard suivant dans le bloc-notes du terminal de développement pour importer AWS Glue bibliothèques dont vous avez besoin, et configurez-en une seule `GlueContext` :

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
```

```
from awsglue.context import GlueContext
from awsglue.job import Job

glueContext = GlueContext(SparkContext.getOrCreate())
```

Étape 3 : examiner les schémas à partir des données de Data Catalog

Ensuite, vous pouvez facilement créer, examiner un `DynamicFrame` à partir du catalogue de données AWS Glue et examiner les schémas des données. Par exemple, pour afficher le schéma de la table `persons_json`, ajoutez les éléments suivants à votre bloc-notes :

```
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators",
    table_name="persons_json")
print "Count: ", persons.count()
persons.printSchema()
```

Voici le résultat des appels d'impression :

```
Count: 1961
root
|-- family_name: string
|-- name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- other_names: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- name: string
|   |   |-- lang: string
|-- sort_name: string
|-- images: array
```

```
|      |-- element: struct
|      |      |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|      |-- element: struct
|      |      |-- type: string
|      |      |-- value: string
|-- death_date: string
```

Chaque personne contenue dans la table est un membre de certains des organismes du Congrès des Etats-Unis.

Pour afficher le schéma de la table `memberships_json`, tapez ce qui suit :

```
memberships = glueContext.create_dynamic_frame.from_catalog(
    database="legislators",
    table_name="memberships_json")
print "Count: ", memberships.count()
memberships.printSchema()
```

La sortie est la suivante :

```
Count:  10439
root
|-- area_id: string
|-- on_behalf_of_id: string
|-- organization_id: string
|-- role: string
|-- person_id: string
|-- legislative_period_id: string
|-- start_date: string
|-- end_date: string
```

Les organizations sont des partis et les deux chambres du Congrès, le Sénat et la Chambre des représentants. Pour afficher le schéma de la table `organizations_json`, tapez ce qui suit :

```
orgs = glueContext.create_dynamic_frame.from_catalog(
```

```
        database="legislators",
        table_name="organizations_json")
print "Count: ", orgs.count()
orgs.printSchema()
```

La sortie est la suivante :

```
Count:  13
root
|-- classification: string
|-- links: array
|   |-- element: struct
|       |-- note: string
|       |-- url: string
|-- image: string
|-- identifiers: array
|   |-- element: struct
|       |-- scheme: string
|       |-- identifier: string
|-- other_names: array
|   |-- element: struct
|       |-- lang: string
|       |-- note: string
|       |-- name: string
|-- id: string
|-- name: string
|-- seats: int
|-- type: string
```

Étape 4 : Filtrer les données

Ensuite, conservez uniquement les champs de votre choix, et renommez `id` en `org_id`. L'ensemble de données est suffisamment petit pour que vous puissiez l'afficher entièrement.

`toDF()` convertit `DynamicFrame` en `DataFrame` Apache Spark, afin que vous puissiez appliquer les transformations qui existent déjà dans Apache Spark SQL :

```
orgs = orgs.drop_fields(['other_names',
                        'identifiers']).rename_field(
                        'id', 'org_id').rename_field(
```



```
'name', 'org_name')
orgs.toDF().show()
```

Le résultat est présenté ci-dessous :

```
+-----+-----+-----+-----+-----+
+-----+-----+
|classification|          org_id|          org_name|          links|seats|
|      type|          image|
+-----+-----+-----+-----+-----+
+-----+-----+
|      party|      party/al|          AL|          null| null|
|      null|          null|
|      party|      party/democrat|      Democrat|[[website,http://...| null|
|      null|https://upload.wi...|
|      party|party/democrat-li...|      Democrat-Liberal|[[website,http://...| null|
|      null|          null|
| legislature|d56acebe-8fdc-47b...|House of Represen...|          null| 435|
lower house|          null|
|      party|      party/independent|      Independent|          null| null|
|      null|          null|
|      party|party/new_progres...|      New Progressive|[[website,http://...| null|
|      null|https://upload.wi...|
|      party|party/popular_dem...|      Popular Democrat|[[website,http://...| null|
|      null|          null|
|      party|      party/republican|      Republican|[[website,http://...| null|
|      null|https://upload.wi...|
|      party|party/republican-...|Republican-Conser...|[[website,http://...| null|
|      null|          null|
|      party|      party/democrat|      Democrat|[[website,http://...| null|
|      null|https://upload.wi...|
|      party|      party/independent|      Independent|          null| null|
|      null|          null|
|      party|      party/republican|      Republican|[[website,http://...| null|
|      null|https://upload.wi...|
| legislature|8fa6c3d2-71dc-478...|          Senate|          null| 100|
upper house|          null|
+-----+-----+-----+-----+-----+
+-----+-----+
```

Tapez la commande suivante pour afficher les organizations qui apparaissent dans memberships :

```
memberships.select_fields(['organization_id']).toDF().distinct().show()
```

Le résultat est présenté ci-dessous :

```
+-----+
| organization_id|
+-----+
|d56acebe-8fdc-47b...|
|8fa6c3d2-71dc-478...|
+-----+
```

Étape 5 : Synthèse

Maintenant, utilisez AWS Glue pour joindre ces tables relationnelles et créer une table historique complète du législateur memberships et ses correspondants. organizations

1. Commencez par joindre persons et memberships à id et person_id.
2. Ensuite, joignez le résultat avec orgs à org_id et organization_id.
3. Ensuite, déplacez les champs redondants, person_id et org_id.

Vous pouvez effectuer toutes ces opérations en une seule ligne de code (étendu) :

```
l_history = Join.apply(orgs,
                      Join.apply(persons, memberships, 'id', 'person_id'),
                      'org_id', 'organization_id').drop_fields(['person_id',
                        'org_id'])
print "Count: ", l_history.count()
l_history.printSchema()
```

La sortie est la suivante :

```
Count:  10439
root
|-- role: string
|-- seats: int
```

```

|-- org_name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- type: string
|-- sort_name: string
|-- area_id: string
|-- images: array
|   |-- element: struct
|   |   |-- url: string
|-- on_behalf_of_id: string
|-- other_names: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- name: string
|   |   |-- lang: string
|-- contact_details: array
|   |-- element: struct
|   |   |-- type: string
|   |   |-- value: string
|-- name: string
|-- birth_date: string
|-- organization_id: string
|-- gender: string
|-- classification: string
|-- death_date: string
|-- legislative_period_id: string
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- image: string
|-- given_name: string
|-- family_name: string
|-- id: string
|-- start_date: string
|-- end_date: string

```

Vous disposez à présent de la table finale que vous pouvez utiliser pour l'analyse. Vous pouvez l'écrire dans un format compact et efficace pour l'analyse, à savoir Parquet, dans lequel vous pouvez exécuter du SQL AWS Glue, Amazon Athena ou Amazon Redshift Spectrum.

L'appel suivant enregistre la table dans plusieurs fichiers afin de prendre en charge des lectures parallèles rapides lors de l'exécution d'une analyse ultérieure :

```
glueContext.write_dynamic_frame.from_options(frame = l_history,
                                             connection_type = "s3",
                                             connection_options = {"path": "s3://glue-sample-target/output-dir/legislator_history"},
                                             format = "parquet")
```

Pour réunir toutes les données d'historique en un seul fichier, vous devez les convertir dans un cadre de données, les repartitionner et les écrire :

```
s_history = l_history.toDF().repartition(1)
s_history.write.parquet('s3://glue-sample-target/output-dir/legislator_single')
```

Sinon, si vous souhaitez les distinguer en fonction du Sénat et de la Chambre des représentants :

```
l_history.toDF().write.parquet('s3://glue-sample-target/output-dir/legislator_part',
                               partitionBy=['org_name'])
```

Étape 6 : Transformer les données pour les bases de données relationnelles

AWS Glue facilite l'écriture des données dans des bases de données relationnelles telles qu'Amazon Redshift, même avec des données semi-structurées. Ainsi, vous obtenez une `relationalize` de transformation, qui aplatit `DynamicFrames`, quelle que soit la complexité des objets du cadre.

Dans cet exemple, à l'aide de `l_history` `DynamicFrame`, transmettez le nom d'une table racine (`hist_root`) et un chemin de travail temporaire `relationalize`. Cela renvoie une `DynamicFrameCollection`. Vous pouvez ensuite répertorier les noms des `DynamicFrames` de cet ensemble :

```
dfc = l_history.relationalize("hist_root", "s3://glue-sample-target/temp-dir/")
dfc.keys()
```

Voici la sortie de l'appel `keys` :

```
[u'hist_root', u'hist_root_contact_details', u'hist_root_links',
 u'hist_root_other_names', u'hist_root_images', u'hist_root_identifiers']
```

Relationalize a décomposé la table d'historique en six nouvelles tables : une table racine qui contient un enregistrement pour chaque objet dans le DynamicFrame et des tables auxiliaires pour les tableaux. La gestion de tableaux dans les bases de données relationnelles est souvent sous-optimale, en particulier lorsque ces tableaux deviennent volumineux. Décomposer les tableaux en différentes tables permet d'accélérer considérablement les requêtes.

Ensuite, consultez la décomposition en examinant `contact_details` :

```
l_history.select_fields('contact_details').printSchema()
dfc.select('hist_root_contact_details').toDF().where("id = 10 or id =
75").orderBy(['id', 'index']).show()
```

Voici la sortie de l'appel `show` :

```
root
|-- contact_details: array
|   |-- element: struct
|   |   |-- type: string
|   |   |-- value: string
+---+-----+-----+-----+-----+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----+-----+-----+
| 10|  0|                fax|                |
| 10|  1|                |          202-225-1314|
| 10|  2|            phone|                |
| 10|  3|                |          202-225-3772|
| 10|  4|            twitter|                |
| 10|  5|                |      MikeRossUpdates|
| 75|  0|                fax|                |
| 75|  1|                |          202-225-7856|
| 75|  2|            phone|                |
| 75|  3|                |          202-225-2711|
| 75|  4|            twitter|                |
| 75|  5|                |          SenCapito|
+---+-----+-----+-----+-----+
```

Le champ `contact_details` était un tableau de structures dans le `DynamicFrame` d'origine. Chaque élément de ces tableaux est une ligne distincte dans la table auxiliaire, indexée par `index`. L'id ici est une clé étrangère dans la table `hist_root` avec la clé `contact_details` :

```
dfc.select('hist_root').toDF().where(
    "contact_details = 10 or contact_details = 75").select(
    ['id', 'given_name', 'family_name', 'contact_details']).show()
```

En voici la sortie :

```
+-----+-----+-----+-----+
|          id|given_name|family_name|contact_details|
+-----+-----+-----+-----+
|f4fc30ee-7b42-432...|      Mike|      Ross|          10|
|e3c60f34-7d1b-4c0...|    Shelley|    Capito|          75|
+-----+-----+-----+-----+
```

Notez dans ces commandes que `toDF()`, puis une expression `where` sont utilisés pour filtrer les lignes à afficher.

Ainsi, la jonction de la table `hist_root` avec les tables auxiliaire vous permet d'effectuer les actions suivantes :

- Charger des données dans les bases de données sans prise en charge par un tableau ;
- Interroger chaque élément individuel dans un tableau à l'aide de SQL.

Stockez et accédez en toute sécurité à vos informations d'identification Amazon Redshift grâce à AWS Glue connexion. Pour plus d'informations sur la création de votre propre connexion, consultez [Connexion aux données](#).

Vous êtes maintenant prêt à écrire vos données dans une connexion en parcourant le `DynamicFrames` un par un :

```
for df_name in dfc.keys():
    m_df = dfc.select(df_name)
    print "Writing to table: ", df_name
```

```
glueContext.write_dynamic_frame.from_jdbc_conf(frame = m_df, connection settings here)
```

Les paramètres de connexion varient en fonction de votre type de base de données relationnelle :

- Pour obtenir des instructions sur l'écriture sur Amazon Redshift, consultez [the section called “Connexions Redshift”](#).
- Pour d'autres bases de données, consultez [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#).

Conclusion

Dans l'ensemble, AWS Glue est très flexible. Il vous permet de réaliser, en quelques lignes de code, ce qui prendrait normalement plusieurs jours pour écrire. Vous pouvez trouver l'intégralité des scripts source-to-target ETL dans le fichier `join_and_relationalize.py` Python du [AWS Glue échantillons](#) sur GitHub.

Exemple de code : préparation des données à l'aide ResolveChoice de Lambda et ApplyMapping

L'ensemble de données utilisé dans cet exemple comprend les données de paiement des prestataires de soins médicaux téléchargées à partir de deux ensembles de données [Data.cms.gov](#) : « Résumé des fournisseurs potentiels du système de paiement pour les patients hospitalisés pour les 100 principaux groupes liés au diagnostic - 2011 » et « Données de facturation des patients hospitalisés pour l'exercice FY2 2011 ». Après le téléchargement des données, nous avons modifié le jeu de données de manière à introduire quelques enregistrements erronés à la fin du fichier. Ce fichier modifié est situé dans un compartiment Amazon S3 public à l'adresse `s3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv`.

Le code source de cet exemple se trouve dans le `data_cleaning_and_lambda.py` fichier du [AWS Glue](#) GitHub référentiel d'exemples.

La méthode préférée pour déboguer Python ou PySpark des scripts pendant l'exécution AWS consiste à utiliser [Notebooks on AWS Glue Studio](#).

Étape 1 : analyser les données dans le compartiment Amazon S3

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. En suivant le processus décrit dans [Configuration d'un crawler](#), créez un nouveau robot d'exploration capable d'explorer le `s3://awsglue-datasets/examples/medicare/`

Medicare_Hospital_Provider.csv fichier et de placer les métadonnées obtenues dans une base de données nommée payments dans le catalogue de données AWS Glue.

3. Exécutez le nouvel crawler, puis activez la base de données payments. Vous devriez constater que l'crawler a créé un tableau de métadonnées nommé medicare dans la base de données après avoir lu le début du fichier pour déterminer son format et son délimiteur.

Le schéma de la nouvelle table medicare se présente comme suit :

Column name	Data type
=====	=====
drp definition	string
provider id	bigint
provider name	string
provider street address	string
provider city	string
provider state	string
provider zip code	bigint
hospital referral region description	string
total discharges	bigint
average covered charges	string
average total payments	string
average medicare payments	string

Étape 2 : Ajouter le script Boilerplate au bloc-notes de point de terminaison de développement

Collez le script standard suivant dans le bloc-notes du terminal de développement pour importer AWS Glue bibliothèques dont vous avez besoin, et configurez-en une seule GlueContext :

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

glueContext = GlueContext(SparkContext.getOrCreate())
```


Étape 3 : Comparer les analyses des différents schémas

Ensuite, vous pouvez voir si le schéma reconnu par un Apache Spark DataFrame est le même que celui de votre AWS Glue Crawler a été enregistré. Exécutez ce code :

```
medicare = spark.read.format(  
    "com.databricks.spark.csv").option(  
    "header", "true").option(  
    "inferSchema", "true").load(  
    's3://aws glue-datasets/examples/medicare/Medicare_Hospital_Provider.csv')  
medicare.printSchema()
```

Voici la sortie de l'appel printSchema :

```
root  
|-- DRG Definition: string (nullable = true)  
|-- Provider Id: string (nullable = true)  
|-- Provider Name: string (nullable = true)  
|-- Provider Street Address: string (nullable = true)  
|-- Provider City: string (nullable = true)  
|-- Provider State: string (nullable = true)  
|-- Provider Zip Code: integer (nullable = true)  
|-- Hospital Referral Region Description: string (nullable = true)  
|-- Total Discharges : integer (nullable = true)  
|-- Average Covered Charges : string (nullable = true)  
|-- Average Total Payments : string (nullable = true)  
|-- Average Medicare Payments: string (nullable = true)
```

Ensuite, examinez le schéma selon lequel AWS Glue DynamicFrame génère :

```
medicare_dynamicframe = glueContext.create_dynamic_frame.from_catalog(  
    database = "payments",  
    table_name = "medicare")  
medicare_dynamicframe.printSchema()
```

La sortie de printSchema est la suivante :

```
root
|-- drg definition: string
|-- provider id: choice
|   |-- long
|   |-- string
|-- provider name: string
|-- provider street address: string
|-- provider city: string
|-- provider state: string
|-- provider zip code: long
|-- hospital referral region description: string
|-- total discharges: long
|-- average covered charges: string
|-- average total payments: string
|-- average medicare payments: string
```

Le `DynamicFrame` génère un schéma dans lequel `provider id` peut être un type `long` ou `string`. Le schéma `DataFrame` répertorie `Provider Id` comme étant un type `string` et le `provider id` répertorie `Data Catalog` comme étant un type `bigint`.

Lequel est correct ? Il existe deux enregistrements à la fin du fichier (sur un total de 160 000 enregistrements) avec des valeurs `string` dans cette colonne. Il s'agit des enregistrements erronés qui ont été introduits pour illustrer un problème.

Pour résoudre ce type de problème, le `AWS Glue DynamicFrame` introduit le concept d'un type de choix. Dans ce cas, `DynamicFrame` montre que les valeurs `long` et `string` peuvent apparaître dans cette colonne. Le `AWS Glue crawler` n'a pas saisi les `string` valeurs car il n'a pris en compte qu'un préfixe de 2 Mo de données. Le `DataFrame Apache Spark` a pris en compte la totalité de l'ensemble de données, mais il a été contraint d'affecter le type le plus général à la colonne, à savoir `string`. En fait, `Spark` a souvent recours au cas le plus général pour des types ou des variations complexes avec lesquels il n'est pas familier.

Pour interroger la colonne `provider id`, commencez par résoudre le type de choix. Vous pouvez utiliser la méthode de transformation `resolveChoice` dans votre `DynamicFrame` pour convertir ces valeurs `string` en valeurs `long` avec une option `cast:long` :

```
medicare_res = medicare_dynamicframe.resolveChoice(specs = [('provider
id','cast:long')])
medicare_res.printSchema()
```

La sortie printSchema est désormais :

```
root
|-- drg definition: string
|-- provider id: long
|-- provider name: string
|-- provider street address: string
|-- provider city: string
|-- provider state: string
|-- provider zip code: long
|-- hospital referral region description: string
|-- total discharges: long
|-- average covered charges: string
|-- average total payments: string
|-- average medicare payments: string
```

Lorsque la valeur était une valeur string qui ne pouvait pas être convertie, AWS Glue a inséré `unnull`.

Une autre option consiste à convertir le type de choix en struct, qui conserve les valeurs des deux types.

Ensuite, regardez les lignes qui étaient anormales :

```
medicare_res.toDF().where("'provider id' is NULL").show()
```

Les informations suivantes s'affichent :

```
+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+
|      drg definition|provider id|  provider name|provider street address|provider
city|provider state|provider zip code|hospital referral region description|total
discharges|average covered charges|average total payments|average medicare payments|
+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+
|948 - SIGNS & SYM...|      null|      INC|      1050 DIVISION ST|
MAUSTON|      WI|      53948|      WI - Madison|
      12|      $11961.41|      $4619.00|      $3775.33|
```

```
|948 - SIGNS & SYM...|      null| INC- ST JOSEPH|      5000 W CHAMBERS ST|
MILWAUKEE|      WI|      53210|      WI - Milwaukee|
      14|      $10514.28|      $5562.50|      $4522.78|
+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+
```

Maintenant, supprimez les deux enregistrements incorrects, comme suit :

```
medicare_dataframe = medicare_res.toDF()
medicare_dataframe = medicare_dataframe.where("'provider id' is NOT NULL")
```

Étape 4 : Mapper les données et utiliser les fonctions Lambda Apache Spark

AWS Glue ne prend pas encore directement en charge les fonctions Lambda, également appelées fonctions définies par l'utilisateur. Mais vous pouvez toujours convertir un `DynamicFrame` vers et depuis un `DataFrame` Apache Spark pour tirer avantage de la fonction Spark en plus des fonctions spécifiques de `DynamicFrames`.

Ensuite, convertissez les informations de paiement en chiffres, de sorte que les moteurs analytiques tels qu'Amazon Redshift ou Amazon Athena puissent analyser les chiffres plus rapidement :

```
from pyspark.sql.functions import udf
from pyspark.sql.types import StringType

chop_f = udf(lambda x: x[1:], StringType())
medicare_dataframe = medicare_dataframe.withColumn(
    "ACC", chop_f(
        medicare_dataframe["average covered charges"])).withColumn(
    "ATP", chop_f(
        medicare_dataframe["average total payments"])).withColumn(
    "AMP", chop_f(
        medicare_dataframe["average medicare payments"]))
medicare_dataframe.select(['ACC', 'ATP', 'AMP']).show()
```

La sortie de l'appel `show` est la suivante :

```
+-----+-----+-----+
|      ACC|      ATP|      AMP|
+-----+-----+-----+
|32963.07|5777.24|4763.73|
```

```
|15131.85|5787.57|4976.71|
|37560.37|5434.95|4453.79|
|13998.28|5417.56|4129.16|
|31633.27|5658.33|4851.44|
|16920.79|6653.80|5374.14|
|11977.13|5834.74|4761.41|
|35841.09|8031.12|5858.50|
|28523.39|6113.38|5228.40|
|75233.38|5541.05|4386.94|
|67327.92|5461.57|4493.57|
|39607.28|5356.28|4408.20|
|22862.23|5374.65|4186.02|
|31110.85|5366.23|4376.23|
|25411.33|5282.93|4383.73|
| 9234.51|5676.55|4509.11|
|15895.85|5930.11|3972.85|
|19721.16|6192.54|5179.38|
|10710.88|4968.00|3898.88|
|51343.75|5996.00|4962.45|
+-----+-----+-----+
only showing top 20 rows
```

Cela reste toujours des chaînes dans les données. Nous pouvons utiliser la puissante méthode de transformation `apply_mapping` pour supprimer, renommer, analyser et imbriquer les données afin que d'autres systèmes et langages de programmation puissent facilement y accéder :

```
from awsglue.dynamicframe import DynamicFrame
medicare_tmp_dyf = DynamicFrame.fromDF(medicare_dataframe, glueContext, "nested")
medicare_nest_dyf = medicare_tmp_dyf.apply_mapping([('drg definition', 'string', 'drg',
    'string'),
    ('provider id', 'long', 'provider.id', 'long'),
    ('provider name', 'string', 'provider.name', 'string'),
    ('provider city', 'string', 'provider.city', 'string'),
    ('provider state', 'string', 'provider.state', 'string'),
    ('provider zip code', 'long', 'provider.zip', 'long'),
    ('hospital referral region description', 'string', 'rr', 'string'),
    ('ACC', 'string', 'charges.covered', 'double'),
    ('ATP', 'string', 'charges.total_pay', 'double'),
    ('AMP', 'string', 'charges.medicare_pay', 'double')])
medicare_nest_dyf.printSchema()
```

La sortie `printSchema` est la suivante :

```

root
|-- drg: string
|-- provider: struct
|   |-- id: long
|   |-- name: string
|   |-- city: string
|   |-- state: string
|   |-- zip: long
|-- rr: string
|-- charges: struct
|   |-- covered: double
|   |-- total_pay: double
|   |-- medicare_pay: double

```

Vous pouvez reconverter les données en DataFrame Spark, comme suit :

```
medicare_nest_dyf.toDF().show()
```

La sortie est la suivante :

```

+-----+-----+-----+-----+
|          drg|          provider|          rr|          charges|
+-----+-----+-----+-----+
|039 - EXTRACRANIA...|[10001,SOUTHEAST ...|    AL - Dothan|[32963.07,5777.24...|
|039 - EXTRACRANIA...|[10005,MARSHALL M...|AL - Birmingham|[15131.85,5787.57...|
|039 - EXTRACRANIA...|[10006,ELIZA COFF...|AL - Birmingham|[37560.37,5434.95...|
|039 - EXTRACRANIA...|[10011,ST VINCENT...|AL - Birmingham|[13998.28,5417.56...|
|039 - EXTRACRANIA...|[10016,SHELBY BAP...|AL - Birmingham|[31633.27,5658.33...|
|039 - EXTRACRANIA...|[10023,BAPTIST ME...|AL - Montgomery|[16920.79,6653.8,...|
|039 - EXTRACRANIA...|[10029,EAST ALABA...|AL - Birmingham|[11977.13,5834.74...|
|039 - EXTRACRANIA...|[10033,UNIVERSITY...|AL - Birmingham|[35841.09,8031.12...|
|039 - EXTRACRANIA...|[10039,HUNTSVILLE...|AL - Huntsville|[28523.39,6113.38...|
|039 - EXTRACRANIA...|[10040,GADSDEN RE...|AL - Birmingham|[75233.38,5541.05...|
|039 - EXTRACRANIA...|[10046,RIVERVIEW ...|AL - Birmingham|[67327.92,5461.57...|
|039 - EXTRACRANIA...|[10055,FLOWERS HO...|    AL - Dothan|[39607.28,5356.28...|
|039 - EXTRACRANIA...|[10056,ST VINCENT...|AL - Birmingham|[22862.23,5374.65...|
|039 - EXTRACRANIA...|[10078,NORTHEAST ...|AL - Birmingham|[31110.85,5366.23...|
|039 - EXTRACRANIA...|[10083,SOUTH BALD...|    AL - Mobile|[25411.33,5282.93...|
|039 - EXTRACRANIA...|[10085,DECATUR GE...|AL - Huntsville|[9234.51,5676.55,...|
|039 - EXTRACRANIA...|[10090,PROVIDENCE...|    AL - Mobile|[15895.85,5930.11...|
|039 - EXTRACRANIA...|[10092,D C H REGI...|AL - Tuscaloosa|[19721.16,6192.54...|
|039 - EXTRACRANIA...|[10100,THOMAS HOS...|    AL - Mobile|[10710.88,4968.0,...|

```

```
|039 - EXTRACRANIA...|[10103,BAPTIST ME...|AL - Birmingham|[51343.75,5996.0,...|
+-----+-----+-----+-----+
only showing top 20 rows
```

Étape 5 : Écrire les données dans Apache Parquet

AWS Glue permet d'écrire facilement les données dans un format tel qu'Apache Parquet que les bases de données relationnelles peuvent utiliser efficacement :

```
glueContext.write_dynamic_frame.from_options(
    frame = medicare_nest_dyf,
    connection_type = "s3",
    connection_options = {"path": "s3://glue-sample-target/output-dir/
medicare_parquet"},
    format = "parquet")
```

AWS Référence des PySpark extensions Glue

AWS Glue a créé les extensions suivantes pour le dialecte PySpark Python.

- [Accès aux paramètres à l'aide de `getResolvedOptions`](#)
- [PySpark types d'extensions](#)
- [DynamicFrame classe](#)
- [DynamicFrameCollection classe](#)
- [DynamicFrameWriter classe](#)
- [DynamicFrameReader classe](#)
- [GlueContext classe](#)

Accès aux paramètres à l'aide de **`getResolvedOptions`**

Le AWS Glue `getResolvedOptions(args, options)` Une fonction utilitaire vous donne accès aux arguments transmis à votre script lorsque vous exécutez une tâche. Pour utiliser cette fonction, commencez par l'importer depuis AWS Glue `utils` module, en même temps que le `sys` module :

```
import sys
from aws glue.utils import getResolvedOptions
```

getResolvedOptions(args, options)

- args - Liste des arguments contenus dans `sys.argv`.
- options - Tableau Python des noms d'arguments que vous souhaitez extraire.

Exemple Récupération des arguments transmis à un JobRun

Supposons que vous ayez créé un JobRun dans un script, peut-être dans une fonction Lambda :

```
response = client.start_job_run(  
    JobName = 'my_test_job',  
    Arguments = {  
        '--day_partition_key': 'partition_0',  
        '--hour_partition_key': 'partition_1',  
        '--day_partition_value': day_partition_value,  
        '--hour_partition_value': hour_partition_value } )
```

Pour extraire les arguments transmis, vous pouvez utiliser la fonction `getResolvedOptions` comme suit :

```
import sys  
from awsglue.utils import getResolvedOptions  
  
args = getResolvedOptions(sys.argv,  
                           ['JOB_NAME',  
                           'day_partition_key',  
                           'hour_partition_key',  
                           'day_partition_value',  
                           'hour_partition_value'])  
print "The day-partition key is: ", args['day_partition_key']  
print "and the day-partition value is: ", args['day_partition_value']
```

Notez que chaque argument est défini avec deux traits d'union au début, puis est référencé dans le script sans trait d'union. Les arguments utilisent uniquement des traits de soulignement, pas des traits d'union. Vos arguments doivent suivre cette convention pour être résolus.

PySpark types d'extensions

Les types utilisés par AWS Glue PySpark extensions.

DataType

Classe de base pour les autres types de AWS Glue.

__init__(properties={})

- `properties` – Propriétés des types de données (facultatif).

typeName(cls)

Renvoie le type de AWS Glue classe de type (c'est-à-dire le nom de classe avec « Type » supprimé à la fin).

- `cls`— Un AWS Glue instance de classe dérivée de `DataType`.

jsonValue()

Renvoie un objet JSON qui contient le type de données et les propriétés de la classe :

```
{
  "dataType": typeName,
  "properties": properties
}
```

AtomicType et dérivés simples

Hérite de la [DataType](#) classe et l'étend, et sert de classe de base pour tous les AWS Glue types de données atomiques.

fromJsonValue(cls, json_value)

Initialise une instance de classe avec les valeurs d'un objet JSON.

- `cls`— Un AWS Glue type d'instance de classe à initialiser.
- `json_value` – Objet JSON à partir duquel charger les paires clé-valeur.

Les types suivants sont des dérivés simples de la classe [AtomicType](#) :

- `BinaryType` – Données binaires.

- `BooleanType` – Valeurs booléennes.
- `ByteType` – Valeur byte.
- `DateType` – Valeur datetime.
- `DoubleType` – Valeur double à virgule flottante.
- `IntegerType` – Une valeur d'entier.
- `LongType` - Entier long.
- `NullType` – Valeur null.
- `ShortType` – Entier court.
- `StringType` – Chaîne texte.
- `TimestampType` – Valeur timestamp (généralement en secondes à partir du 01/01/1970).
- `UnknownType` – Valeur de type non identifié.

`DecimalType(AtomicType)`

Hérite depuis la classe [AtomicType](#) et l'étend pour représenter un nombre décimal (nombre exprimé en décimales, par opposition aux nombres binaires de base 2).

`__init__(precision=10, scale=2, properties={})`

- `precision` – Nombre de chiffres dans le nombre décimal (facultatif ; la valeur par défaut est 10).
- `scale` – Nombre de chiffres à droite du point décimal (facultatif ; la valeur par défaut est 2).
- `properties` – Propriétés du nombre décimal (facultatif).

`EnumType(AtomicType)`

Hérite de la classe [AtomicType](#) et l'étend pour représenter une énumération des options valides.

`__init__(options)`

- `options` – Liste des options énumérées.

Types de collections

- [ArrayType\(DataType\)](#)
- [ChoiceType\(DataType\)](#)

- [MapType\(DataType\)](#)
- [Field\(Object\)](#)
- [StructType\(DataType\)](#)
- [EntityType\(DataType\)](#)

ArrayType(DataType)

__init__(elementType=UnknownType(), properties={})

- `elementType`— Le type des éléments du tableau (facultatif ; la valeur par défaut est `UnknownType`).
- `properties` – Propriétés du tableau (facultatif).

ChoiceType(DataType)

__init__(choices=[], properties={})

- `choices` – Liste des choix possibles (facultatif).
- `properties` – Propriétés de ces options (facultatif).

add(new_choice)

Ajoute un nouveau choix à la liste des choix possibles.

- `new_choice` – Choix à ajouter à la liste des choix possibles.

merge(new_choices)

Fusionne une liste de nouveaux choix avec la liste de choix existantes.

- `new_choices` – Liste des nouveaux choix à fusionner avec les choix existants.

MapType(DataType)

__init__(valueType=UnknownType, properties={})

- `valueType`— Le type de valeurs sur la carte (facultatif ; la valeur par défaut est `UnknownType`).

- `properties` – Propriétés de la map (facultatif).

`Field(Object)`

Crée un objet champ hors d'un objet qui dérive de [DataType](#).

`__init__(name, dataType, properties={})`

- `name` – Nom à attribuer au champ.
- `dataType` – Objet à partir duquel créer un champ.
- `properties` – Propriétés du champ (facultatif).

`StructType(DataType)`

Définit une structure de données (`struct`).

`__init__(fields=[], properties={})`

- `fields` – Liste des champs (de type `Field`) à inclure dans la structure (facultatif).
- `properties` – Propriétés de la structure (facultatif).

`add(field)`

- `field` – Objet de type `Field` à ajouter à la structure.

`hasField(field)`

Renvoie `True` si la structure dispose d'un champ du même nom, ou `False` si ce n'est pas le cas.

- `field` – Nom de champ ou objet de type `Field` dont le nom est utilisé.

`getField(field)`

- `field` – nom de champ ou objet de type `Field` dont le nom est utilisé. Si la structure a un champ du même nom, il est retourné.

EntityType(DataType)

`__init__(entity, base_type, properties)`

Cette classe n'a pas encore été implémentée.

Autres types

- [DataSource\(objet\)](#)
- [DataSink\(objet\)](#)

DataSource(objet)

`__init__(j_source, sql_ctx, name)`

- `j_source` – Source de données.
- `sql_ctx` – Contexte SQL.
- `name` – Nom de la source de données.

`setFormat(format, **options)`

- `format` – Format à définir pour la source de données.
- `options` – Collection d'options à définir pour la source de données. Pour plus d'informations sur ces options de format, consultez [the section called “Options de format de données”](#).

`getFrame()`

Renvoie un `DynamicFrame` pour la source de données.

DataSink(objet)

`__init__(j_sink, sql_ctx)`

- `j_sink` – Récepteur à créer.
- `sql_ctx` – Contexte SQL pour le récepteur de données.

setFormat(format, **options)

- `format` – Format à définir pour le récepteur de données.
- `options` – Collection d'options à définir pour le récepteur de données. Pour plus d'informations sur ces options de format, consultez [the section called “Options de format de données”](#).

setAccumulableSize(size)

- `size` – Taille cumulaire à définir, en octets.

writeFrame(dynamic_frame, info="")

- `dynamic_frame` – Objet `DynamicFrame` à écrire.
- `info` – Informations sur l'objet `DynamicFrame` (facultatif).

write(dynamic_frame_or_dfc, info="")

Écrit un `DynamicFrame` ou un `DynamicFrameCollection`.

- `dynamic_frame_or_dfc` – Objet `DynamicFrame` ou `DynamicFrameCollection` à écrire.
- `info` – Informations sur le `DynamicFrame` ou `DynamicFrames` à écrire (facultatif).

DynamicFrame classe

L'une des principales abstractions dans Apache Spark est le `DataFrame` SparkSQL, ce qui est similaire à la construction `DataFrame` présente dans R et Pandas. A `DataFrame` est similaire à une table et prend en charge les opérations de style fonctionnel (`map/reduce/filter/etc.`) et les opérations SQL (sélection, projet, agrégation).

`DataFrames` Les sont puissants et largement utilisés, mais ils présentent des limitations au niveau des opérations d'extraction, de transformation et de chargement (opérations ETL). Cela signifie notamment qu'un schéma doit être spécifié avant tout chargement de données. Pour faire face à ce problème, SparkSQL effectue deux passages sur les données : un premier passage pour déduire le schéma et un second pour charger les données. Cependant, cette inférence est limitée et ne prend pas en compte la désorganisation des données. Par exemple, un même champ peut avoir différents

types dans différents enregistrements. L'opération est souvent abandonnée par Apache Spark, qui indique que le type est `string` en tenant compte du texte du champ d'origine. Cette information peut être erronée et vous pouvez souhaiter exercer un meilleur contrôle sur la résolution des écarts entre les schémas. Et pour les ensembles de données volumineux, un passage supplémentaire sur les données source peut s'avérer hors de prix.

Pour remédier à ces limites, AWS Glue introduit le `DynamicFrame`. Un `DynamicFrame` est similaire à un `DataFrame`, mais chaque enregistrement y est auto-descriptif : initialement, aucun schéma n'est donc requis. Au lieu de cela, AWS Glue calcule un schéma on-the-fly lorsque cela est nécessaire et code explicitement les incohérences du schéma à l'aide d'un type de choix (ou d'union). Vous pouvez résoudre ces incohérences afin de rendre vos ensembles de données compatibles avec les magasins de données qui nécessitent un schéma fixe.

De même, un `DynamicRecord` représente un enregistrement logique au sein d'un `DynamicFrame`. Il est comparable à une ligne dans un `DataFrame` Spark, à la différence qu'il est auto-descriptif et peut être utilisé pour les données qui ne sont pas conformes à un schéma fixe. Lorsque vous utilisez AWS Glue with PySpark, vous ne manipulez généralement pas de manière indépendante les `DynamicRecords`. Vous allez plutôt transformer le jeu de données par le biais de son `DynamicFrame`.

Vous pouvez convertir `DynamicFrames` vers et depuis `DataFrames` après la résolution des incohérences de schémas.

– construction –

- [`\_\_init\_\_`](#)
- [`fromDF`](#)
- [`toDF`](#)

`__init__`

`__init__(jdf, glue_ctx, name)`

- `jdf` – Référence à la trame de données dans la machine virtuelle Java (JVM).
- `glue_ctx` – Un objet [GlueContext](#) classe.
- `name` – Nom de chaîne facultatif, vide par défaut.

fromDF

fromDF(dataframe, glue_ctx, name)

Convertit un DataFrame en DynamicFrame via la conversion de champs DataFrame en champs DynamicRecord. Renvoie un nouveau DynamicFrame.

Un DynamicRecord représente un enregistrement logique dans un DynamicFrame. Il est comparable à une ligne dans un DataFrame Spark, à la différence qu'il est auto-descriptif et peut être utilisé pour les données qui ne sont pas conformes à un schéma fixe.

Cette fonction s'attend à ce que les colonnes dont les noms sont dupliqués dans votre DataFrame aient déjà été résolues.

- **dataframe** – DataFrame Apache Spark SQL à convertir (obligatoire).
- **glue_ctx** – Objet [GlueContext classe](#) qui spécifie le contexte pour cette transformation (obligatoire).
- **name**— Le nom du résultat DynamicFrame (facultatif depuis AWS Glue 3.0).

toDF

toDF(options)

Convertit un DynamicFrame en DataFrame Apache Spark via la conversion de DynamicRecords en champs DataFrame. Renvoie un nouveau DataFrame.

Un DynamicRecord représente un enregistrement logique dans un DynamicFrame. Il est comparable à une ligne dans un DataFrame Spark, à la différence qu'il est auto-descriptif et peut être utilisé pour les données qui ne sont pas conformes à un schéma fixe.

- **options** – liste d'options. Vous permet de définir des options supplémentaires pour le processus de conversion. Voici quelques options valides que vous pouvez utiliser avec le paramètre « options » :
 - **format**— spécifie le format des données, tel que json, csv, parquet).
 - **separator or sep**— pour les fichiers CSV, indique le délimiteur.
 - **header**— pour les fichiers CSV, indique si la première ligne est un en-tête (vrai/faux).
 - **inferSchema**— demande à Spark de déduire automatiquement le schéma (vrai/faux).

Voici un exemple d'utilisation du paramètre `options` avec la méthode `toDF` :

```
from awsglue.context import GlueContext
from awsglue.dynamicframe import DynamicFrame
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

csv_dyf = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://my-bucket/path/to/csv/"]},
    format="csv"
)
csv_cf = csv_dyf.toDF(options={
    "separator": ",",
    "header": "true",
    "inferSchema": "true"
})
```

Spécifiez le type de cible si vous choisissez le type d'action Project et Cast. Voici quelques exemples :

```
>>>toDF([ResolveOption("a.b.c", "KeepAsStruct")])
>>>toDF([ResolveOption("a.b.c", "Project", DoubleType())])
```

– informations –

- [count](#)
- [schéma](#)
- [printSchema](#)
- [show](#)
- [repartition](#)
- [coalesce](#)

count

`count( )` – Renvoie le nombre de lignes dans le DataFrame sous-jacent.

schéma

`schema( )` – Renvoie le schéma de ce `DynamicFrame` ou, s'il n'est pas disponible, le schéma du DataFrame sous-jacent.

Pour plus d'informations sur les types de `DynamicFrame` qui composent ce schéma, consultez [the section called “Types”](#).

printSchema

`printSchema( )` – Imprime le schéma du DataFrame sous-jacent.

show

`show(num_rows)` – Imprime un nombre de lignes spécifié du DataFrame sous-jacent.

repartition

`repartition(numPartitions)` – renvoie un nouvel objet `DynamicFrame` avec des partitions `numPartitions`.

coalesce

`coalesce(numPartitions)` – renvoie un nouvel objet `DynamicFrame` avec des partitions `numPartitions`.

– transformations –

- [apply_mapping](#)
- [drop_fields](#)
- [filtre](#)
- [join](#)
- [map](#)
- [mergeDynamicFrame](#)
- [relationalize](#)

- [rename_field](#)
- [resolveChoice](#)
- [select_fields](#)
- [spigot](#)
- [split_fields](#)
- [split_rows](#)
- [unbox](#)
- [the section called “union”](#)
- [unnest](#)
- [unnest_ddb_json](#)
- [write](#)

apply_mapping

apply_mapping(mappings, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)

Applique un mappage déclaratif à une image `DynamicFrame` et renvoie une nouvelle image `DynamicFrame` sur laquelle ces mappages sont appliqués. Les champs non spécifiés sont omis dans le nouveau `DynamicFrame`.

- **mappings**— Une liste de tuples de mappage (obligatoire). Chacun étant composé comme suit : (colonne source, type source, colonne cible, type cible).

Si la colonne source comporte un point « . » dans le nom, vous devez l'entourer d'accent graves « `` ». Par exemple, pour mapper `this.old.name` (chaîne) à `thisNewName`, vous devez utiliser le tuple suivant :

```
("`this.old.name`", "string", "thisNewName", "string")
```

- **transformation_ctx** – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- **info** – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).
- **stageThreshold** – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'erreur générée par le processus (facultatif) La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.

- `totalThreshold` – Nombre d'erreurs rencontrées jusqu'à cette transformation, incluse, et qui doit entraîner l'arrêt du processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.

Exemple : Utilisez `apply_mapping` afin de renommer des champs ainsi que de modifier ses types

L'exemple de code suivant montre la `apply_mapping` méthode d'utilisation relative au renommage des champs sélectionnés ainsi qu' à la modification des types de champs.

Note

Pour accéder au jeu de données utilisé dans cet exemple, voir [Exemple de code : Données de jonction et de mise en relation](#) et suivez les instructions de la section [Étape 1 : analyser les données dans le compartiment Amazon S3](#).

```
# Example: Use apply_mapping to reshape source data into
# the desired column names and types as a new DynamicFrame

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Create a DynamicFrame and view its schema
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="persons_json"
)
print("Schema for the persons DynamicFrame:")
persons.printSchema()

# Select and rename fields, change field type
print("Schema for the persons_mapped DynamicFrame, created with apply_mapping:")
persons_mapped = persons.apply_mapping(
    [
        ("family_name", "String", "last_name", "String"),
        ("name", "String", "first_name", "String"),
        ("birth_date", "String", "date_of_birth", "Date"),
    ]
)
```

```
)  
persons_mapped.printSchema()
```

Sortie

Schema for the persons DynamicFrame:

```
root  
|-- family_name: string  
|-- name: string  
|-- links: array  
|   |-- element: struct  
|   |   |-- note: string  
|   |   |-- url: string  
|-- gender: string  
|-- image: string  
|-- identifiers: array  
|   |-- element: struct  
|   |   |-- scheme: string  
|   |   |-- identifier: string  
|-- other_names: array  
|   |-- element: struct  
|   |   |-- lang: string  
|   |   |-- note: string  
|   |   |-- name: string  
|-- sort_name: string  
|-- images: array  
|   |-- element: struct  
|   |   |-- url: string  
|-- given_name: string  
|-- birth_date: string  
|-- id: string  
|-- contact_details: array  
|   |-- element: struct  
|   |   |-- type: string  
|   |   |-- value: string  
|-- death_date: string
```

Schema for the persons_mapped DynamicFrame, created with apply_mapping:

```
root  
|-- last_name: string  
|-- first_name: string  
|-- date_of_birth: date
```

drop_fields

drop_fields(paths, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)

Appelle la transformation [FlatMap classe](#) afin de supprimer des champs d'un `DynamicFrame`. Renvoie un nouveau `DynamicFrame` avec les champs supprimés spécifiés.

- **paths** - Une liste de chaînes. Chacune contient le chemin d'accès complet à un nœud de champ que vous souhaitez supprimer. Vous pouvez utiliser la notation par points pour spécifier des champs imbriqués. Par exemple, si le champ `first` est un enfant du champ `namedans` dans l'arborescence, vous spécifiez `"name.first"` pour le chemin d'accès.

Si le nom d'un nœud de champ contient un `.` littéral, vous devez l'entourer d'accent graves (```).

- **transformation_ctx** – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- **info** – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).
- **stageThreshold** – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'erreur générée par le processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.
- **totalThreshold** – Nombre d'erreurs rencontrées jusqu'à cette transformation, incluse, et qui doit entraîner l'arrêt du processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.

Exemple : utilisez `supprimer les chams` pour supprimer les champs d'un **DynamicFrame**

Cet exemple de code utilise le `drop_fields` méthode pour supprimer les champs de niveau supérieur et imbriqués sélectionnés d'un `DynamicFrame`.

Exemple de jeu de données

L'exemple utilise l'ensemble de données suivant qui est représenté par `EXAMPLE-FRIENDS-DATAtable` dans le code :

```
{"name": "Sally", "age": 23, "location": {"state": "WY", "county": "Fremont"},  
  "friends": []}
```

```
{ "name": "Varun", "age": 34, "location": { "state": "NE", "county": "Douglas" },  
  "friends": [ { "name": "Arjun", "age": 3 } ] }  
{ "name": "George", "age": 52, "location": { "state": "NY" }, "friends": [ { "name":  
  "Fred" }, { "name": "Amy", "age": 15 } ] }  
{ "name": "Haruki", "age": 21, "location": { "state": "AK", "county": "Denali" } }  
{ "name": "Sheila", "age": 63, "friends": [ { "name": "Nancy", "age": 22 } ] }
```

Exemple de code

```
# Example: Use drop_fields to remove top-level and nested fields from a DynamicFrame.  
# Replace MY-EXAMPLE-DATABASE with your Glue Data Catalog database name.  
# Replace EXAMPLE-FRIENDS-DATA with your table name.  
  
from pyspark.context import SparkContext  
from awsglue.context import GlueContext  
  
# Create GlueContext  
sc = SparkContext.getOrCreate()  
glueContext = GlueContext(sc)  
  
# Create a DynamicFrame from Glue Data Catalog  
glue_source_database = "MY-EXAMPLE-DATABASE"  
glue_source_table = "EXAMPLE-FRIENDS-DATA"  
  
friends = glueContext.create_dynamic_frame.from_catalog(  
    database=glue_source_database, table_name=glue_source_table  
)  
print("Schema for friends DynamicFrame before calling drop_fields:")  
friends.printSchema()  
  
# Remove location.county, remove friends.age, remove age  
friends = friends.drop_fields(paths=["age", "location.county", "friends.age"])  
print("Schema for friends DynamicFrame after removing age, county, and friend age:")  
friends.printSchema()
```

Sortie

```
Schema for friends DynamicFrame before calling drop_fields:  
root  
|-- name: string  
|-- age: int  
|-- location: struct  
|   |-- state: string
```

```
|    |-- county: string
|-- friends: array
|    |-- element: struct
|    |    |-- name: string
|    |    |-- age: int
```

Schema for friends DynamicFrame after removing age, county, and friend age:

```
root
|-- name: string
|-- location: struct
|    |-- state: string
|-- friends: array
|    |-- element: struct
|    |    |-- name: string
```

filtre

filter(f, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)

Renvoie un nouveau DynamicFrame contient tout DynamicRecords de l'entrée DynamicFrame qui correspondent à la fonction de prédicat f.

- **f** – Fonction de prédicat à appliquer au paramètre DynamicFrame. La fonction doit prendre un DynamicRecord en tant qu'argument et renvoyer la valeur True si le DynamicRecord répond aux critères du filtre, ou la valeur False si ce n'est pas le cas (obligatoire).

Un DynamicRecord représente un enregistrement logique dans un DynamicFrame. Il est comparable à une ligne dans un Spark DataFrame, à la différence qu'il est auto-descriptif et peut être utilisé pour les données qui ne sont pas conformes à un schéma fixe.

- **transformation_ctx** – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- **info** – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).
- **stageThreshold** – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'erreur générée par le processus (facultatif) La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.
- **totalThreshold** – Nombre d'erreurs rencontrées jusqu'à cette transformation, incluse, et qui doit entraîner l'arrêt du processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.

Exemple : Utiliser un filtre pour obtenir une sélection de champs filtrée

Cet exemple utilise le `filter` Méthode de création d'un nouveau `DynamicFrame` qui inclut une sélection filtrée d'un autre `DynamicFrame` des champs.

Comme le `map` Méthode, `filter` prend une fonction comme argument qui est appliquée à chaque enregistrement de l'`originalDynamicFrame`. La fonction prend un enregistrement en entrée et renvoie une valeur booléenne. Si la valeur de retour est vraie, l'enregistrement est inclus dans le résultat `DynamicFrame`. Si c'est faux, le dossier est omis.

Note

Pour accéder au jeu de données utilisé dans cet exemple, voir [Exemple de code : préparation des données à l'aide ResolveChoice de Lambda et ApplyMapping](#) et suivez les instructions de la section [Étape 1 : analyser les données dans le compartiment Amazon S3](#).

```
# Example: Use filter to create a new DynamicFrame
# with a filtered selection of records

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Create DynamicFrame from Glue Data Catalog
medicare = glueContext.create_dynamic_frame.from_options(
    "s3",
    {
        "paths": [
            "s3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv"
        ]
    },
    "csv",
    {"withHeader": True},
)

# Create filtered DynamicFrame with custom lambda
# to filter records by Provider State and Provider City
sac_or_mon = medicare.filter(
```

```
f=lambda x: x["Provider State"] in ["CA", "AL"]
and x["Provider City"] in ["SACRAMENTO", "MONTGOMERY"]
)

# Compare record counts
print("Unfiltered record count: ", medicare.count())
print("Filtered record count:  ", sac_or_mon.count())
```

Sortie

```
Unfiltered record count:  163065
Filtered record count:    564
```

join

join(paths1, paths2, frame2, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)

Effectue une jointure d'égalité avec un autre `DynamicFrame` et renvoie le `DynamicFrame` obtenu.

- `paths1` – Liste des clés dans cette trame à joindre.
- `paths2` – Liste des clés dans l'autre trame à joindre.
- `frame2` – Autre `DynamicFrame` à joindre.
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).
- `stageThreshold` – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'erreur générée par le processus (facultatif) La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.
- `totalThreshold` – Nombre d'erreurs rencontrées jusqu'à cette transformation, incluse, et qui doit entraîner l'arrêt du processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.

Exemple : Utiliser la jointure pour combiner `DynamicFrames`

Cet exemple utilise la `join` méthode pour effectuer une jointure sur trois `DynamicFrames`.

AWS Glue effectue la jointure en fonction des clés de champ que vous fournissez. Le résultat

`DynamicFrame` contient les lignes des deux cadres d'origine où les clés spécifiées correspondent.

Notez que le `jointransform` conserve tous les champs intacts. Cela signifie que les champs que vous spécifiez comme correspondants apparaissent dans le résultat `DynamicFrame`, même s'ils sont redondants et contiennent les mêmes clés. Dans cet exemple, nous utilisons `drop_field` pour supprimer ces clés redondantes après la jointure.

Note

Pour accéder au jeu de données utilisé dans cet exemple, voir [Exemple de code : Données de jonction et de mise en relation](#) et suivez les instructions de la section [Étape 1 : analyser les données dans le compartiment Amazon S3](#).

```
# Example: Use join to combine data from three DynamicFrames

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Load DynamicFrames from Glue Data Catalog
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="persons_json"
)
memberships = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="memberships_json"
)
orgs = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="organizations_json"
)
print("Schema for the persons DynamicFrame:")
persons.printSchema()
print("Schema for the memberships DynamicFrame:")
memberships.printSchema()
print("Schema for the orgs DynamicFrame:")
orgs.printSchema()

# Join persons and memberships by ID
persons_memberships = persons.join(
    paths1=["id"], paths2=["person_id"], frame2=memberships
)
```

```
# Rename and drop fields from orgs
# to prevent field name collisions with persons_memberships
orgs = (
    orgs.drop_fields(["other_names", "identifiers"])
    .rename_field("id", "org_id")
    .rename_field("name", "org_name")
)

# Create final join of all three DynamicFrames
legislators_combined = orgs.join(
    paths1=["org_id"], paths2=["organization_id"], frame2=persons_memberships
).drop_fields(["person_id", "org_id"])

# Inspect the schema for the joined data
print("Schema for the new legislators_combined DynamicFrame:")
legislators_combined.printSchema()
```

Sortie

Schema for the persons DynamicFrame:

```
root
|-- family_name: string
|-- name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- other_names: array
|   |-- element: struct
|   |   |-- lang: string
|   |   |-- note: string
|   |   |-- name: string
|-- sort_name: string
|-- images: array
|   |-- element: struct
|   |   |-- url: string
```

```
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|   |-- element: struct
|   |   |-- type: string
|   |   |-- value: string
|-- death_date: string
```

Schema for the memberships DynamicFrame:

```
root
|-- area_id: string
|-- on_behalf_of_id: string
|-- organization_id: string
|-- role: string
|-- person_id: string
|-- legislative_period_id: string
|-- start_date: string
|-- end_date: string
```

Schema for the orgs DynamicFrame:

```
root
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- other_names: array
|   |-- element: struct
|   |   |-- lang: string
|   |   |-- note: string
|   |   |-- name: string
|-- id: string
|-- classification: string
|-- name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- image: string
|-- seats: int
|-- type: string
```

Schema for the new legislators_combined DynamicFrame:

```
root
```

```
|-- role: string
|-- seats: int
|-- org_name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- type: string
|-- sort_name: string
|-- area_id: string
|-- images: array
|   |-- element: struct
|   |   |-- url: string
|-- on_behalf_of_id: string
|-- other_names: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- name: string
|   |   |-- lang: string
|-- contact_details: array
|   |-- element: struct
|   |   |-- type: string
|   |   |-- value: string
|-- name: string
|-- birth_date: string
|-- organization_id: string
|-- gender: string
|-- classification: string
|-- legislative_period_id: string
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- image: string
|-- given_name: string
|-- start_date: string
|-- family_name: string
|-- id: string
|-- death_date: string
|-- end_date: string
```

map

map(f, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)

Renvoie un nouveau `DynamicFrame` qui résulte de l'application de la fonction de mappage spécifiée à tous les enregistrements dans le `DynamicFrame` d'origine.

- `f` – Fonction de mappage à appliquer à tous les enregistrements dans le paramètre `DynamicFrame`. La fonction doit prendre un `DynamicRecord` comme argument et renvoyer un nouveau `DynamicRecord` (obligatoire).

Un `DynamicRecord` représente un enregistrement logique dans un `DynamicFrame`. Il est comparable à une ligne dans un `DataFrame` Apache Spark, à la différence qu'il est auto-descriptif et peut être utilisé pour les données qui ne sont pas conformes à un schéma fixe.

- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.

Exemple : utilisez la carte pour appliquer une fonction à chaque enregistrement dans un **DynamicFrame**

Cet exemple illustre comment utiliser `map` méthode pour appliquer une fonction à chaque enregistrement d'un `DynamicFrame`. Plus précisément, cet exemple applique une fonction appelée `MergeAddress` à chaque enregistrement afin de fusionner plusieurs champs d'adresse en un seul `struct` type.

Note

Pour accéder au jeu de données utilisé dans cet exemple, voir [Exemple de code : préparation des données à l'aide ResolveChoice de Lambda et ApplyMapping](#) et suivez les instructions de la section [Étape 1 : analyser les données dans le compartiment Amazon S3](#).

```
# Example: Use map to combine fields in all records
```

```
# of a DynamicFrame

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Create a DynamicFrame and view its schema
medicare = glueContext.create_dynamic_frame.from_options(
    "s3",
    {"paths": ["s3://awsglue-datasets/examples/medicare/
Medicare_Hospital_Provider.csv"]},
    "csv",
    {"withHeader": True})
print("Schema for medicare DynamicFrame:")
medicare.printSchema()

# Define a function to supply to the map transform
# that merges address fields into a single field
def MergeAddress(rec):
    rec["Address"] = {}
    rec["Address"]["Street"] = rec["Provider Street Address"]
    rec["Address"]["City"] = rec["Provider City"]
    rec["Address"]["State"] = rec["Provider State"]
    rec["Address"]["Zip.Code"] = rec["Provider Zip Code"]
    rec["Address"]["Array"] = [rec["Provider Street Address"], rec["Provider City"],
rec["Provider State"], rec["Provider Zip Code"]]
    del rec["Provider Street Address"]
    del rec["Provider City"]
    del rec["Provider State"]
    del rec["Provider Zip Code"]
    return rec

# Use map to apply MergeAddress to every record
mapped_medicare = medicare.map(f = MergeAddress)
print("Schema for mapped_medicare DynamicFrame:")
mapped_medicare.printSchema()
```


Sortie

```
Schema for medicare DynamicFrame:
root
|-- DRG Definition: string
|-- Provider Id: string
|-- Provider Name: string
|-- Provider Street Address: string
|-- Provider City: string
|-- Provider State: string
|-- Provider Zip Code: string
|-- Hospital Referral Region Description: string
|-- Total Discharges: string
|-- Average Covered Charges: string
|-- Average Total Payments: string
|-- Average Medicare Payments: string
```

```
Schema for mapped_medicare DynamicFrame:
root
|-- Average Total Payments: string
|-- Average Covered Charges: string
|-- DRG Definition: string
|-- Average Medicare Payments: string
|-- Hospital Referral Region Description: string
|-- Address: struct
|   |-- Zip.Code: string
|   |-- City: string
|   |-- Array: array
|   |   |-- element: string
|   |-- State: string
|   |-- Street: string
|-- Provider Id: string
|-- Total Discharges: string
|-- Provider Name: string
```

mergeDynamicFrame

mergeDynamicFrame(stage_dynamic_frame, primary_keys, transformation_ctx = "", options = {}, info = "", stageThreshold = 0, totalThreshold = 0)

Fusionne cette trame DynamicFrame avec une trame DynamicFrame intermédiaire basée sur les clés primaires spécifiées pour identifier les enregistrements. Les registres en double (registres avec les mêmes clés primaires) ne sont pas dédupliqués. Si aucun enregistrement ne correspond dans

la trame intermédiaire, tous les enregistrements (y compris les doublons) sont conservés dans la source. Si la trame intermédiaire contient des enregistrements correspondants, les enregistrements de la trame intermédiaire remplacent les enregistrements de la source dans AWS Glue.

- `stage_dynamic_frame` – trame `DynamicFrame` intermédiaire à fusionner.
- `primary_keys` – liste des champs de clé primaire permettant de faire correspondre les enregistrements des trames dynamiques source et intermédiaire.
- `transformation_ctx` – chaîne unique utilisée pour récupérer les métadonnées relatives à la transformation en cours (facultatif).
- `options` – chaîne de paires nom-valeur JSON qui fournissent des informations supplémentaires pour cette transformation. Cet argument n'est actuellement pas utilisé.
- `info` – A `String`. Toute chaîne à associer à des erreurs dans cette transformation.
- `stageThreshold` – A `Long`. Nombre d'erreurs identifiées dans la transformation donnée et à corriger lors du traitement.
- `totalThreshold` – A `Long`. Nombre total d'erreurs identifiées dans la transformation donnée et qui doivent être corrigées lors du traitement.

La méthode renvoie une nouvelle image `DynamicFrame` obtenue en fusionnant `DynamicFrame` avec l'image `DynamicFrame` intermédiaire.

La trame `DynamicFrame` renvoyée contient l'enregistrement A dans les cas suivants :

- Si A se trouve à la fois dans la trame source et la trame intermédiaire, c'est la valeur A de la trame intermédiaire qui est renvoyée.
- Si A se trouve dans la table source et si `A.primaryKeys` ne se trouve pas dans l'image `stagingDynamicFrame`, A n'est pas mis à jour dans la table intermédiaire.

L'image source et l'image intermédiaire n'ont pas besoin d'avoir le même schéma.

Exemple : `mergeDynamicFrame` à utiliser pour fusionner deux **DynamicFrames** en fonction d'une clé primaire

L'exemple de code suivant montre comment utiliser la méthode `mergeDynamicFrame` pour fusionner une image `DynamicFrame` avec une image `DynamicFrame` « intermédiaire », sur la base de la clé primaire `id`.

Exemple de jeu de données

L'exemple utilise deux images DynamicFrames d'une collection DynamicFrameCollection appelée `split_rows_collection`. Vous trouverez ci-dessous la liste des clés de la collection `split_rows_collection`.

```
dict_keys(['high', 'low'])
```

Exemple de code

```
# Example: Use mergeDynamicFrame to merge DynamicFrames
# based on a set of specified primary keys

from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.transforms import SelectFromCollection

# Inspect the original DynamicFrames
frame_low = SelectFromCollection.apply(dfc=split_rows_collection, key="low")
print("Inspect the DynamicFrame that contains rows where ID < 10")
frame_low.toDF().show()

frame_high = SelectFromCollection.apply(dfc=split_rows_collection, key="high")
print("Inspect the DynamicFrame that contains rows where ID > 10")
frame_high.toDF().show()

# Merge the DynamicFrames based on the "id" primary key
merged_high_low = frame_high.mergeDynamicFrame(
    stage_dynamic_frame=frame_low, primary_keys=["id"]
)

# View the results where the ID is 1 or 20
print("Inspect the merged DynamicFrame that contains the combined rows")
merged_high_low.toDF().where("id = 1 or id= 20").orderBy("id").show()
```

Sortie

```
Inspect the DynamicFrame that contains rows where ID < 10
+---+-----+-----+-----+-----+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----+-----+-----+
| 1| 0|fax|202-225-3307|
| 1| 1|phone|202-225-5731|
| 2| 0|fax|202-225-3307|
```

	2	1	phone	202-225-5731
	3	0	fax	202-225-3307
	3	1	phone	202-225-5731
	4	0	fax	202-225-3307
	4	1	phone	202-225-5731
	5	0	fax	202-225-3307
	5	1	phone	202-225-5731
	6	0	fax	202-225-3307
	6	1	phone	202-225-5731
	7	0	fax	202-225-3307
	7	1	phone	202-225-5731
	8	0	fax	202-225-3307
	8	1	phone	202-225-5731
	9	0	fax	202-225-3307
	9	1	phone	202-225-5731
	10	0	fax	202-225-6328
	10	1	phone	202-225-4576

```
+---+-----+-----+-----+-----+-----+-----+
```

only showing top 20 rows

Inspect the DynamicFrame that contains rows where ID > 10

```
+---+-----+-----+-----+-----+-----+-----+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----+-----+-----+-----+-----+
| 11|  0|      fax|      202-225-6328|
| 11|  1|     phone|      202-225-4576|
| 11|  2|    twitter|    RepTrentFranks|
| 12|  0|      fax|      202-225-6328|
| 12|  1|     phone|      202-225-4576|
| 12|  2|    twitter|    RepTrentFranks|
| 13|  0|      fax|      202-225-6328|
| 13|  1|     phone|      202-225-4576|
| 13|  2|    twitter|    RepTrentFranks|
| 14|  0|      fax|      202-225-6328|
| 14|  1|     phone|      202-225-4576|
| 14|  2|    twitter|    RepTrentFranks|
| 15|  0|      fax|      202-225-6328|
| 15|  1|     phone|      202-225-4576|
| 15|  2|    twitter|    RepTrentFranks|
| 16|  0|      fax|      202-225-6328|
| 16|  1|     phone|      202-225-4576|
| 16|  2|    twitter|    RepTrentFranks|
| 17|  0|      fax|      202-225-6328|
| 17|  1|     phone|      202-225-4576|
```

```
+---+-----+-----+-----+-----+
only showing top 20 rows

Inspect the merged DataFrame that contains the combined rows
+---+-----+-----+-----+-----+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----+-----+-----+
|  1|   0|                fax|        202-225-3307|
|  1|   1|                phone|        202-225-5731|
| 20|   0|                fax|        202-225-5604|
| 20|   1|                phone|        202-225-6536|
| 20|   2|            twitter|        USRepLong|
+---+-----+-----+-----+-----+
```

relationalize

**relationalize(root_table_name, staging_path, options,
transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)**

Convertit une image DataFrame sous une forme adaptée à une base de données relationnelle. La mise en relation d'une image DataFrame est particulièrement utile lorsque vous souhaitez déplacer des données d'un environnement NoSQL tel que DynamoDB vers une base de données relationnelle telle que MySQL.

La transformation génère une liste des images en désimbriquant les colonnes imbriquées et en faisant pivoter les colonnes de tableau. Vous pouvez joindre les colonnes du tableau ayant été pivotées à l'aide de la clé générée au cours de la phase de désimbrication.

- **root_table_name** – Nom de la table racine.
- **staging_path** – Chemin d'accès auquel la méthode peut stocker des partitions des tables dynamiques au format CSV format (facultatif). Les tables dynamiques sont lues à partir de ce chemin.
- **options** – Dictionnaire des paramètres facultatifs.
- **transformation_ctx** – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- **info** – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).

- `stageThreshold` – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'erreur générée par le processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.
- `totalThreshold` – Nombre d'erreurs rencontrées jusqu'à cette transformation, incluse, et qui doit entraîner l'arrêt du processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.

Exemple : utiliser la méthode `relationalize` pour aplatir un schéma imbriqué dans une image

DynamicFrame

Cet exemple de code utilise la méthode `relationalize` pour aplatir un schéma imbriqué sous une forme adaptée à une base de données relationnelle.

Exemple de jeu de données

L'exemple utilise une image `DynamicFrame` appelée `legislators_combined` avec le schéma suivant. `legislators_combined` possède plusieurs champs imbriqués tels que `links`, `images` et `contact_details`, qui seront aplaties par la transformation `relationalize`.

```
root
|-- role: string
|-- seats: int
|-- org_name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- type: string
|-- sort_name: string
|-- area_id: string
|-- images: array
|   |-- element: struct
|   |   |-- url: string
|-- on_behalf_of_id: string
|-- other_names: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- name: string
|   |   |-- lang: string
|-- contact_details: array
|   |-- element: struct
```

```

|      |      |-- type: string
|      |      |-- value: string
|-- name: string
|-- birth_date: string
|-- organization_id: string
|-- gender: string
|-- classification: string
|-- legislative_period_id: string
|-- identifiers: array
|      |-- element: struct
|      |      |-- scheme: string
|      |      |-- identifier: string
|-- image: string
|-- given_name: string
|-- start_date: string
|-- family_name: string
|-- id: string
|-- death_date: string
|-- end_date: string

```

Exemple de code

```

# Example: Use relationalize to flatten
# a nested schema into a format that fits
# into a relational database.
# Replace DOC-EXAMPLE-S3-BUCKET/tmpDir with your own location.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Apply relationalize and inspect new tables
legislators_relationalized = legislators_combined.relationalize(
    "l_root", "s3://DOC-EXAMPLE-BUCKET/tmpDir"
)
legislators_relationalized.keys()

# Compare the schema of the contact_details
# nested field to the new relationalized table that
# represents it

```

```
legislators_combined.select_fields("contact_details").printSchema()
legislators_relationalized.select("l_root_contact_details").toDF().where(
    "id = 10 or id = 75"
).orderBy(["id", "index"]).show()
```

Sortie

La sortie suivante vous permet de comparer le schéma du champ imbriqué appelé `contact_details` à la table créée par la transformation `relationalize`. Notez que les enregistrements de la table renvoient vers la table principale à l'aide d'une clé étrangère appelée `id` et d'une colonne `index` représentant les positions du tableau.

```
dict_keys(['l_root', 'l_root_images', 'l_root_links', 'l_root_other_names',
'l_root_contact_details', 'l_root_identifiers'])
```

```
root
```

```
|-- contact_details: array
|   |-- element: struct
|       |-- type: string
|       |-- value: string
```

```
+---+-----+-----+-----+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----+-----+
| 10|  0|                fax|          202-225-4160|
| 10|  1|                phone|          202-225-3436|
| 75|  0|                fax|          202-225-6791|
| 75|  1|                phone|          202-225-2861|
| 75|  2|            twitter|          RepSamFarr|
+---+-----+-----+-----+
```

rename_field

```
rename_field(oldName, newName, transformation_ctx="", info="",
stageThreshold=0, totalThreshold=0)
```

Renomme un champ dans ce `DynamicFrame` et renvoie un nouveau `DynamicFrame` avec le champ renommé.

- `oldName` – Chemin d'accès complet au nœud que vous souhaitez renommer.

Si l'ancien nom contient des points, `RenameField` ne fonctionne pas à moins que vous ne le délimitiez avec des apostrophes inverses (` `). Par exemple, pour remplacer `this.old.name` par `thisNewName`, vous devez appeler `rename_field` comme suit.

```
newDyF = oldDyF.rename_field("`this.old.name`", "thisNewName")
```

- `newName` – Nouveau nom, sous forme de chemin d'accès complet.
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).
- `stageThreshold` – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'erreur générée par le processus (facultatif) La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.
- `totalThreshold` – Nombre d'erreurs rencontrées jusqu'à cette transformation, incluse, et qui doit entraîner l'arrêt du processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.

Exemple : utiliser la méthode `rename_field` pour renommer des champs dans une image

DynamicFrame

Cet exemple de code utilise la méthode `rename_field` pour renommer les champs dans une image `DynamicFrame`. Notez que l'exemple utilise le chaînage de méthode pour renommer plusieurs champs en même temps.

Note

Pour accéder au jeu de données utilisé dans cet exemple, voir [Exemple de code : Données de jonction et de mise en relation](#) et suivez les instructions de la section [Étape 1 : analyser les données dans le compartiment Amazon S3](#).

Exemple de code

```
# Example: Use rename_field to rename fields
# in a DynamicFrame

from pyspark.context import SparkContext
```

```
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Inspect the original orgs schema
orgs = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="organizations_json"
)
print("Original orgs schema: ")
orgs.printSchema()

# Rename fields and view the new schema
orgs = orgs.rename_field("id", "org_id").rename_field("name", "org_name")
print("New orgs schema with renamed fields: ")
orgs.printSchema()
```

Sortie

```
Original orgs schema:
root
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- other_names: array
|   |-- element: struct
|   |   |-- lang: string
|   |   |-- note: string
|   |   |-- name: string
|-- id: string
|-- classification: string
|-- name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- image: string
|-- seats: int
|-- type: string
```

New orgs schema with renamed fields:

```

root
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- other_names: array
|   |-- element: struct
|   |   |-- lang: string
|   |   |-- note: string
|   |   |-- name: string
|-- classification: string
|-- org_id: string
|-- org_name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- image: string
|-- seats: int
|-- type: string

```

resolveChoice

resolveChoice(specs = None, choice = "" , database = None , table_name = None , transformation_ctx="", info="", stageThreshold=0, totalThreshold=0, catalog_id = None)

Résout un type de choix au sein de ce DynamicFrame et renvoie le nouveau DynamicFrame.

- specs – Liste d'ambiguïtés spécifiques à résoudre, apparaissant sous forme de tuple: (field_path, action).

Il existe deux façons d'utiliser resolveChoice. La première consiste à utiliser l'argument specs pour spécifier une séquence de champs spécifiques et la façon de les résoudre. L'autre mode pour resolveChoice consiste à utiliser l'argument choice afin de spécifier une seule résolution pour tous les ChoiceTypes.

Les valeurs pour specs sont spécifiées en tant que tuples composés de paires (field_path, action). La valeur field_path identifie un élément ambigu spécifique, et la valeur action identifie la résolution correspondante. Les actions possibles sont les suivantes :

- `cast: type` – tente de convertir toutes les valeurs vers le type spécifié. Par exemple :
`cast:int`.
- `make_cols` – Convertit chaque type distinct en une colonne avec le nom `columnName_type`. Résout une ambiguïté potentielle en aplatissant les données. Par exemple, si `columnA` peut être un `int` ou un `string`, la résolution consisterait à produire deux colonnes nommées `columnA_int` et `columnA_string` dans le `DynamicFrame` obtenu.
- `make_struct` – résout une ambiguïté potentielle en utilisant un `struct` pour représenter les données. Par exemple, si des données d'une colonne peuvent être de type `int` ou `string`, l'action `make_struct` produit une colonne de structures dans l'image `DynamicFrame` obtenue. Chaque structure contient à la fois des données de type `int` et des données de type `string`.
- `project: type` – résout une ambiguïté potentielle en projetant toutes les données sur l'un des types de données possibles. Par exemple, si des données d'une colonne peuvent être un `int` ou un `string`, une action `project:string` produit une colonne dans le `DynamicFrame` obtenu, où toutes les valeurs `int` ont été converties en chaînes.

Si le `field_path` identifie un tableau, placez des crochets vides après le nom du tableau pour éviter toute ambiguïté. Par exemple, supposons que vous travailliez avec les données structurées comme suit :

```
"myList": [  
  { "price": 100.00 },  
  { "price": "$100.00" }  
]
```

Vous pouvez sélectionner la version numérique plutôt que la version chaîne du prix en définissant `field_path` sur `"myList[].price"` et action sur `"cast:double"`.

Note

Vous ne pouvez utiliser qu'un seul des paramètres `specs` et `choice`. Si le paramètre `specs` n'est pas `None`, alors le paramètre `choice` doit être une chaîne vide. Inversement, si le paramètre `choice` n'est pas une chaîne vide, alors le paramètre `specs` doit être `None`.

- `choice` – spécifie une résolution unique pour tous les `ChoiceTypes`. Vous pouvez utiliser cela lorsque la liste complète des `ChoiceTypes` est inconnue avant l'exécution. En plus des

actions répertoriées précédemment pour specs, cet argument prend également en charge l'action suivante :

- `match_catalog` – tente de convertir chaque `ChoiceType` dans le type correspondant de table Data Catalog spécifiée.
- `database` – base de données Data Catalog à utiliser avec l'action `match_catalog`.
- `table_name` – table Data Catalog à utiliser avec l'action `match_catalog`.
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).
- `stageThreshold` – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'erreur générée par le processus (facultatif) La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.
- `totalThreshold` – Nombre d'erreurs rencontrées jusqu'à cette transformation incluse, et qui doit entraîner l'arrêt du processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas être arrêté dans ce cas.
- `catalog_id` – ID du catalogue Data Catalog auquel vous accédez (ID du compte Data Catalog). Lorsque cette option est définie sur `None` (valeur par défaut), l'ID de catalogue du compte appelant est utilisé.

Exemple : utiliser la méthode `resolveChoice` pour gérer une colonne contenant plusieurs types

Cet exemple de code utilise la méthode `resolveChoice` pour spécifier comment gérer une colonne `DynamicFrame` contenant des valeurs de plusieurs types. L'exemple montre deux méthodes courantes pour gérer une colonne de types différents :

- Convertir la colonne en un seul type de données.
- Conserver tous les types dans des colonnes distinctes.

Exemple de jeu de données

Note

Pour accéder au jeu de données utilisé dans cet exemple, voir [Exemple de code : préparation des données à l'aide ResolveChoice de Lambda et ApplyMapping](#) et suivez les instructions de la section [Étape 1 : analyser les données dans le compartiment Amazon S3](#).

L'exemple utilise une image DynamicFrame appelée `medicare` avec le schéma suivant :

```
root
|-- drg definition: string
|-- provider id: choice
|   |-- long
|   |-- string
|-- provider name: string
|-- provider street address: string
|-- provider city: string
|-- provider state: string
|-- provider zip code: long
|-- hospital referral region description: string
|-- total discharges: long
|-- average covered charges: string
|-- average total payments: string
|-- average medicare payments: string
```

Exemple de code

```
# Example: Use resolveChoice to handle
# a column that contains multiple types

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Load the input data and inspect the "provider id" column
medicare = glueContext.create_dynamic_frame.from_catalog(
    database="payments", table_name="medicare_hospital_provider_csv"
)
print("Inspect the provider id column:")
medicare.toDF().select("provider id").show()

# Cast provider id to type long
medicare_resolved_long = medicare.resolveChoice(specs=[("provider id", "cast:long")])
print("Schema after casting provider id to type long:")
medicare_resolved_long.printSchema()
medicare_resolved_long.toDF().select("provider id").show()
```

```
# Create separate columns
# for each provider id type
medicare_resolved_cols = medicare.resolveChoice(choice="make_cols")
print("Schema after creating separate columns for each type:")
medicare_resolved_cols.printSchema()
medicare_resolved_cols.toDF().select("provider id_long", "provider id_string").show()
```

Sortie

Inspect the 'provider id' column:

```
+-----+
|provider id|
+-----+
|  [10001,]|
|  [10005,]|
|  [10006,]|
|  [10011,]|
|  [10016,]|
|  [10023,]|
|  [10029,]|
|  [10033,]|
|  [10039,]|
|  [10040,]|
|  [10046,]|
|  [10055,]|
|  [10056,]|
|  [10078,]|
|  [10083,]|
|  [10085,]|
|  [10090,]|
|  [10092,]|
|  [10100,]|
|  [10103,]|
+-----+
```

only showing top 20 rows

Schema after casting 'provider id' to type long:

```
root
|-- drg definition: string
|-- provider id: long
|-- provider name: string
|-- provider street address: string
|-- provider city: string
```

```

|-- provider state: string
|-- provider zip code: long
|-- hospital referral region description: string
|-- total discharges: long
|-- average covered charges: string
|-- average total payments: string
|-- average medicare payments: string

```

```
+-----+
```

```
|provider id|
```

```
+-----+
```

```
|      10001|
```

```
|      10005|
```

```
|      10006|
```

```
|      10011|
```

```
|      10016|
```

```
|      10023|
```

```
|      10029|
```

```
|      10033|
```

```
|      10039|
```

```
|      10040|
```

```
|      10046|
```

```
|      10055|
```

```
|      10056|
```

```
|      10078|
```

```
|      10083|
```

```
|      10085|
```

```
|      10090|
```

```
|      10092|
```

```
|      10100|
```

```
|      10103|
```

```
+-----+
```

only showing top 20 rows

Schema after creating separate columns for each type:

```
root
```

```
 |-- drg definition: string
```

```
 |-- provider id_string: string
```

```
 |-- provider id_long: long
```

```
 |-- provider name: string
```

```
 |-- provider street address: string
```

```
 |-- provider city: string
```

```
 |-- provider state: string
```

```
 |-- provider zip code: long
```



```
|-- hospital referral region description: string
|-- total discharges: long
|-- average covered charges: string
|-- average total payments: string
|-- average medicare payments: string
```

```
+-----+-----+
|provider id_long|provider id_string|
+-----+-----+
|          10001|          null|
|          10005|          null|
|          10006|          null|
|          10011|          null|
|          10016|          null|
|          10023|          null|
|          10029|          null|
|          10033|          null|
|          10039|          null|
|          10040|          null|
|          10046|          null|
|          10055|          null|
|          10056|          null|
|          10078|          null|
|          10083|          null|
|          10085|          null|
|          10090|          null|
|          10092|          null|
|          10100|          null|
|          10103|          null|
+-----+-----+
only showing top 20 rows
```

`select_fields`

`select_fields(paths, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Renvoie un nouveau `DynamicFrame` contenant les champs sélectionnés.

- `paths` - Une liste de chaînes. Chaque chaîne est un chemin d'accès au nœud de niveau supérieur que vous souhaitez sélectionner.

- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).
- `stageThreshold` – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'erreur générée par le processus (facultatif) La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.
- `totalThreshold` – Nombre d'erreurs rencontrées jusqu'à cette transformation, incluse, et qui doit entraîner l'arrêt du processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.

Exemple : utilisez `select_fields` pour créer un nouveau **DynamicFrame** avec les champs sélectionnés

L'exemple de code suivant illustre comment utiliser `select_fields` Méthode de création d'un nouveau `DynamicFrame` avec une liste de champs sélectionnés parmi un `DynamicFrame`.

Note

Pour accéder au jeu de données utilisé dans cet exemple, voir [Exemple de code : Données de jonction et de mise en relation](#) et suivez les instructions de la section [Étape 1 : analyser les données dans le compartiment Amazon S3](#).

```
# Example: Use select_fields to select specific fields from a DynamicFrame

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Create a DynamicFrame and view its schema
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="persons_json"
)
print("Schema for the persons DynamicFrame:")
persons.printSchema()

# Create a new DynamicFrame with chosen fields
```

```
names = persons.select_fields(paths=["family_name", "given_name"])
print("Schema for the names DynamicFrame, created with select_fields:")
names.printSchema()
names.toDF().show()
```

Sortie

Schema for the persons DynamicFrame:

```
root
|-- family_name: string
|-- name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- other_names: array
|   |-- element: struct
|   |   |-- lang: string
|   |   |-- note: string
|   |   |-- name: string
|-- sort_name: string
|-- images: array
|   |-- element: struct
|   |   |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|   |-- element: struct
|   |   |-- type: string
|   |   |-- value: string
|-- death_date: string
```

Schema for the names DynamicFrame:

```
root
|-- family_name: string
|-- given_name: string
```

```
+-----+-----+
|family_name|given_name|
+-----+-----+
|    Collins|  Michael|
|   Huizenga|    Bill|
|   Clawson|   Curtis|
|   Solomon|   Gerald|
|    Rigell|   Edward|
|    Crapo|  Michael|
|    Hutto|    Earl|
|    Ertel|   Allen|
|   Minish|   Joseph|
|  Andrews|   Robert|
|   Walden|    Greg|
|    Kazen| Abraham|
|   Turner| Michael|
|    Kolbe|   James|
| Lowenthal|    Alan|
|   Capuano| Michael|
|  Schrader|    Kurt|
|   Nadler| Jerrold|
|   Graves|    Tom|
|  McMillan|   John|
+-----+-----+
only showing top 20 rows
```

simplify_ddb_json

simplify_ddb_json(): DynamicFrame

Simplifie les colonnes imbriquées DynamicFrame qui se trouvent spécifiquement dans la structure JSON DynamoDB et renvoie une nouvelle colonne simplifiée. DynamicFrame S'il existe plusieurs types ou types de carte dans un type de liste, les éléments de la liste ne seront pas simplifiés. Notez qu'il s'agit d'un type de transformation spécifique qui se comporte différemment de la unnest transformation normale et qui nécessite que les données figurent déjà dans la structure JSON DynamoDB. Pour plus d'informations, consultez [JSON DynamoDB](#).

Par exemple, le schéma d'une lecture d'exportation avec la structure JSON DynamoDB pourrait ressembler à ce qui suit :

```
root
```

```

|-- Item: struct
|   |-- parentMap: struct
|   |   |-- M: struct
|   |   |   |-- childMap: struct
|   |   |   |   |-- M: struct
|   |   |   |   |   |-- appName: struct
|   |   |   |   |   |   |-- S: string
|   |   |   |   |   |   |-- packageName: struct
|   |   |   |   |   |   |   |-- S: string
|   |   |   |   |   |   |   |-- updatedAt: struct
|   |   |   |   |   |   |   |   |-- N: string
|   |   |-- strings: struct
|   |   |   |-- SS: array
|   |   |   |   |-- element: string
|   |   |-- numbers: struct
|   |   |   |-- NS: array
|   |   |   |   |-- element: string
|   |   |-- binaries: struct
|   |   |   |-- BS: array
|   |   |   |   |-- element: string
|   |   |-- isDDBJson: struct
|   |   |   |-- BOOL: boolean
|   |   |-- nullValue: struct
|   |   |   |-- NULL: boolean

```

La transformation `simplify_ddb_json()` convertirait ceci en :

```

root
|-- parentMap: struct
|   |-- childMap: struct
|   |   |-- appName: string
|   |   |-- packageName: string
|   |   |-- updatedAt: string
|-- strings: array
|   |-- element: string
|-- numbers: array
|   |-- element: string
|-- binaries: array
|   |-- element: string
|-- isDDBJson: boolean
|-- nullValue: null

```

Exemple : utilisez `simplify_ddb_json` pour appeler un DynamoDB JSON simplify

Cet exemple de code utilise la `simplify_ddb_json` méthode permettant d'utiliser le connecteur d'exportation AWS Glue DynamoDB, d'invoquer un code JSON Simplify DynamoDB et d'imprimer le nombre de partitions.

Exemple de code

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext()
glueContext = GlueContext(sc)

dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type = "dynamodb",
    connection_options = {
        'dynamodb.export': 'ddb',
        'dynamodb.tableArn': '<table arn>',
        'dynamodb.s3.bucket': '<bucket name>',
        'dynamodb.s3.prefix': '<bucket prefix>',
        'dynamodb.s3.bucketOwner': '<account_id of bucket>'
    }
)
simplified = dynamicFrame.simplify_ddb_json()
print(simplified.getNumPartitions())
```

spigot

spigot(path, options={})

Écrit des exemples d'enregistrement sur une destination spécifiée pour vous aider à vérifier les transformations effectuées par votre tâche.

- `path` – Chemin d'accès de la destination sur laquelle écrire (obligatoire).
- `options` – Paires clé-valeur spécifiant des options (facultatif). L'option "topk" indique que les premiers enregistrements k doivent être écrits. L'option "prob" indique la probabilité (sous forme de décimale) de choisir un enregistrement donné. Vous pouvez l'utiliser pour sélectionner les enregistrements à écrire.
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).

Exemple : utiliser la méthode `spigot` pour écrire des exemples de champs d'une image

DynamicFrame vers Amazon S3

Cet exemple de code utilise la méthode `spigot` pour écrire des exemples d'enregistrements dans un compartiment Amazon S3 après avoir appliqué la transformation `select_fields`.

Exemple de jeu de données

Note

Pour accéder au jeu de données utilisé dans cet exemple, voir [Exemple de code : Données de jonction et de mise en relation](#) et suivez les instructions de la section [Étape 1 : analyser les données dans le compartiment Amazon S3](#).

L'exemple utilise une image `DynamicFrame` appelée `persons` avec le schéma suivant :

```
root
|-- family_name: string
|-- name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- other_names: array
|   |-- element: struct
|   |   |-- lang: string
|   |   |-- note: string
|   |   |-- name: string
|-- sort_name: string
|-- images: array
|   |-- element: struct
|   |   |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
```

```
|-- contact_details: array
|   |-- element: struct
|       |-- type: string
|       |-- value: string
|-- death_date: string
```

Exemple de code

```
# Example: Use spigot to write sample records
# to a destination during a transformation
# from pyspark.context import SparkContext.
# Replace DOC-EXAMPLE-BUCKET with your own location.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Load table data into a DynamicFrame
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="persons_json"
)

# Perform the select_fields on the DynamicFrame
persons = persons.select_fields(paths=["family_name", "given_name", "birth_date"])

# Use spigot to write a sample of the transformed data
# (the first 10 records)
spigot_output = persons.spigot(
    path="s3://DOC-EXAMPLE-BUCKET", options={"topk": 10}
)

# Example: Use spigot to write sample records
# to a destination during a transformation
# from pyspark.context import SparkContext.
# Replace DOC-EXAMPLE-BUCKET with your own location.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
```



```
glueContext = GlueContext(sc)

# Load table data into a DynamicFrame
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="persons_json"
)

# Perform the select_fields on the DynamicFrame
persons = persons.select_fields(paths=["family_name", "given_name", "birth_date"])

# Use spigot to write a sample of the transformed data
# (the first 10 records)
spigot_output = persons.spigot(
    path="s3://DOC-EXAMPLE-BUCKET", options={"topk": 10}
)
```

Sortie

Voici un exemple des données que spigot écrit dans Amazon S3. Étant donné que l'exemple de code spécifie `options={"topk": 10}`, les exemples de données contiennent les 10 premiers enregistrements.

```
{
  "family_name": "Collins",
  "given_name": "Michael",
  "birth_date": "1944-10-15"
},
{
  "family_name": "Huizenga",
  "given_name": "Bill",
  "birth_date": "1969-01-31"
},
{
  "family_name": "Clawson",
  "given_name": "Curtis",
  "birth_date": "1959-09-28"
},
{
  "family_name": "Solomon",
  "given_name": "Gerald",
  "birth_date": "1930-08-14"
},
{
  "family_name": "Rigell",
  "given_name": "Edward",
  "birth_date": "1960-05-28"
},
{
  "family_name": "Crapo",
  "given_name": "Michael",
  "birth_date": "1951-05-20"
},
{
  "family_name": "Hutto",
  "given_name": "Earl",
  "birth_date": "1926-05-12"
},
{
  "family_name": "Ertel",
  "given_name": "Allen",
  "birth_date": "1937-11-07"
},
{
  "family_name": "Minish",
  "given_name": "Joseph",
  "birth_date": "1916-09-01"
},
{
  "family_name": "Andrews",
  "given_name": "Robert",
  "birth_date": "1957-08-04"
}
```

split_fields

split_fields(paths, name1, name2, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)

Renvoie une nouvelle collection `DynamicFrameCollection` qui contient deux images `DynamicFrames`. La première image `DynamicFrame` contient tous les nœuds qui ont été fractionnés, et la seconde contient les nœuds qui restent.

- `paths` – Liste de chaînes, chacune étant un chemin d'accès complet à un nœud que vous souhaitez fractionner en un nouveau `DynamicFrame`.
- `name1` – Chaîne de nom pour le `DynamicFrame` fractionné.
- `name2` – Chaîne de nom pour le `DynamicFrame` qui reste après le fractionnement des nœuds spécifiés.
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).
- `stageThreshold` – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'erreur générée par le processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.
- `totalThreshold` – Nombre d'erreurs rencontrées jusqu'à cette transformation, incluse, et qui doit entraîner l'arrêt du processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.

Exemple : utiliser la méthode `split_fields` pour fractionner les champs sélectionnés en une image **DynamicFrame** distincte

Cet exemple de code utilise la méthode `split_fields` pour fractionner une liste de champs spécifiés en une image `DynamicFrame` distincte.

Exemple de jeu de données

L'exemple utilise une image `DynamicFrame` appelée `l_root_contact_details` qui provient d'une collection nommée `legislators_relationalized`.

`l_root_contact_details` contient le schéma et les entrées suivantes.

```
root
|-- id: long
|-- index: int
|-- contact_details.val.type: string
|-- contact_details.val.value: string

+---+-----+-----+-----+-----+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----+-----+-----+
```

	1	0	phone	202-225-5265
	1	1	twitter	kathyhochul
	2	0	phone	202-225-3252
	2	1	twitter	repjackyrosen
	3	0	fax	202-225-1314
	3	1	phone	202-225-3772
...				

Exemple de code

```
# Example: Use split_fields to split selected
# fields into a separate DynamicFrame

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Load the input DynamicFrame and inspect its schema
frame_to_split = legislators_relationalized.select("l_root_contact_details")
print("Inspect the input DynamicFrame schema:")
frame_to_split.printSchema()

# Split id and index fields into a separate DynamicFrame
split_fields_collection = frame_to_split.split_fields(["id", "index"], "left", "right")

# Inspect the resulting DynamicFrames
print("Inspect the schemas of the DynamicFrames created with split_fields:")
split_fields_collection.select("left").printSchema()
split_fields_collection.select("right").printSchema()
```

Sortie

Inspect the input DynamicFrame's schema:

```
root
|-- id: long
|-- index: int
|-- contact_details.val.type: string
|-- contact_details.val.value: string
```

Inspect the schemas of the DynamicFrames created with split_fields:

```
root
|-- id: long
|-- index: int

root
|-- contact_details.val.type: string
|-- contact_details.val.value: string
```

split_rows

split_rows(comparison_dict, name1, name2, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)

Scinde une ou plusieurs lignes d'un objet `DynamicFrame` en un nouveau `DynamicFrame`.

La méthode renvoie une nouvelle collection `DynamicFrameCollection` qui contient deux images `DynamicFrames`. La première image `DynamicFrame` contient toutes les lignes qui ont été fractionnées, et la seconde contient les lignes qui restent.

- `comparison_dict` – Dictionnaire dans lequel la clé est un chemin d'accès à une colonne et la valeur est un autre dictionnaire permettant de mapper les comparateurs aux valeurs auxquelles les valeurs de la colonne sont comparées. Par exemple, `{"age": {">": 10, "<": 20}}` fractionne toutes les lignes dont la valeur de la colonne d'âge est supérieure à 10 et inférieure à 20.
- `name1` – Chaîne de nom pour le `DynamicFrame` fractionné.
- `name2` – Chaîne de nom pour le `DynamicFrame` qui reste après le fractionnement des nœuds spécifiés.
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).
- `stageThreshold` – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'erreur générée par le processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.
- `totalThreshold` – Nombre d'erreurs rencontrées jusqu'à cette transformation, incluse, et qui doit entraîner l'arrêt du processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.

Exemple : utiliser la méthode `split_rows` pour fractionner des lignes en une image **DynamicFrame**

Cet exemple de code utilise la méthode `split_rows` pour fractionner des lignes en une image `DynamicFrame` en se basant sur la valeur du champ `id`.

Exemple de jeu de données

L'exemple utilise une image `DynamicFrame` appelée `l_root_contact_details` qui est sélectionnée à partir d'une collection nommée `legislators_relationalized`.

`l_root_contact_details` contient le schéma et les entrées suivantes.

```
root
|-- id: long
|-- index: int
|-- contact_details.val.type: string
|-- contact_details.val.value: string
```

id	index	contact_details.val.type	contact_details.val.value
1	0	phone	202-225-5265
1	1	twitter	kathyhochul
2	0	phone	202-225-3252
2	1	twitter	repjackyrosen
3	0	fax	202-225-1314
3	1	phone	202-225-3772
3	2	twitter	MikeRossUpdates
4	0	fax	202-225-1314
4	1	phone	202-225-3772
4	2	twitter	MikeRossUpdates
5	0	fax	202-225-1314
5	1	phone	202-225-3772
5	2	twitter	MikeRossUpdates
6	0	fax	202-225-1314
6	1	phone	202-225-3772
6	2	twitter	MikeRossUpdates
7	0	fax	202-225-1314
7	1	phone	202-225-3772
7	2	twitter	MikeRossUpdates
8	0	fax	202-225-1314

Exemple de code

```
# Example: Use split_rows to split up
# rows in a DynamicFrame based on value

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Retrieve the DynamicFrame to split
frame_to_split = legislators_relationalized.select("l_root_contact_details")

# Split up rows by ID
split_rows_collection = frame_to_split.split_rows({"id": {">": 10}}, "high", "low")

# Inspect the resulting DynamicFrames
print("Inspect the DynamicFrame that contains IDs < 10")
split_rows_collection.select("low").toDF().show()
print("Inspect the DynamicFrame that contains IDs > 10")
split_rows_collection.select("high").toDF().show()
```

Sortie

Inspect the DynamicFrame that contains IDs < 10

```
+---+-----+-----+-----+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----+-----+
| 1|    0|           phone|      202-225-5265|
| 1|    1|          twitter|    kathyhochul|
| 2|    0|           phone|      202-225-3252|
| 2|    1|          twitter|    repjackyroten|
| 3|    0|            fax|      202-225-1314|
| 3|    1|           phone|      202-225-3772|
| 3|    2|          twitter|    MikeRossUpdates|
| 4|    0|            fax|      202-225-1314|
| 4|    1|           phone|      202-225-3772|
| 4|    2|          twitter|    MikeRossUpdates|
| 5|    0|            fax|      202-225-1314|
| 5|    1|           phone|      202-225-3772|
| 5|    2|          twitter|    MikeRossUpdates|
```

	6	0	fax	202-225-1314
	6	1	phone	202-225-3772
	6	2	twitter	MikeRossUpdates
	7	0	fax	202-225-1314
	7	1	phone	202-225-3772
	7	2	twitter	MikeRossUpdates
	8	0	fax	202-225-1314

```
+---+-----+-----+-----+-----+-----+
```

only showing top 20 rows

Inspect the DynamicFrame that contains IDs > 10

```
+---+-----+-----+-----+-----+-----+
```

id	index	contact_details.val.type	contact_details.val.value
----	-------	--------------------------	---------------------------

```
+---+-----+-----+-----+-----+-----+
```

	11	0	phone	202-225-5476
	11	1	twitter	RepDavidYoung
	12	0	phone	202-225-4035
	12	1	twitter	RepStephMurphy
	13	0	fax	202-226-0774
	13	1	phone	202-225-6335
	14	0	fax	202-226-0774
	14	1	phone	202-225-6335
	15	0	fax	202-226-0774
	15	1	phone	202-225-6335
	16	0	fax	202-226-0774
	16	1	phone	202-225-6335
	17	0	fax	202-226-0774
	17	1	phone	202-225-6335
	18	0	fax	202-226-0774
	18	1	phone	202-225-6335
	19	0	fax	202-226-0774
	19	1	phone	202-225-6335
	20	0	fax	202-226-0774
	20	1	phone	202-225-6335

```
+---+-----+-----+-----+-----+-----+
```

only showing top 20 rows

unbox

unbox(path, format, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0, **options)

Effectue une opération unbox sur un champ de chaîne (ou le reformate) dans une image DynamicFrame et renvoie une nouvelle image DynamicFrame contenant les enregistrements DynamicRecords sur lesquels l'opération unbox a été effectuée.

Un DynamicRecord représente un enregistrement logique dans un DynamicFrame. Il est comparable à une ligne dans un DataFrame Apache Spark, à la différence qu'il est auto-descriptif et peut être utilisé pour les données qui ne sont pas conformes à un schéma fixe.

- **path** – Chemin d'accès complet au nœud de chaîne pour lequel vous souhaitez effectuer une opération unbox.
- **format** – spécification de format (facultatif). Vous l'utilisez pour un Amazon S3 ou AWS Glue connexion qui prend en charge plusieurs formats. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- **transformation_ctx** – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- **info** – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).
- **stageThreshold** – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'erreur générée par le processus (facultatif) La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.
- **totalThreshold** – Nombre d'erreurs rencontrées jusqu'à cette transformation, incluse, et qui doit entraîner l'arrêt du processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.
- **options** – Un ou plusieurs des éléments suivants :
 - **separator** – Chaîne contenant le caractère de séparation.
 - **escaper** – Chaîne contenant le caractère d'échappement.
 - **skipFirst** – Valeur booléenne indiquant s'il faut ignorer la première instance.
 - **withSchema** : une chaîne contenant une représentation JSON du schéma du nœud. Le format de la représentation JSON d'un schéma est défini par la sortie de `StructType.json()`.
 - **withHeader** – Valeur booléenne indiquant si un en-tête est inclus.

Exemple : utiliser la méthode `unbox` pour effectuer une opération `unbox` sur un champ de chaîne en un champ `struct`

Cet exemple de code utilise la méthode `unbox` pour effectuer une opération `unbox` sur un champ de chaîne dans une image `DynamicFrame` (ou la reformater) en un champ de type `struct`.

Exemple de jeu de données

L'exemple utilise une image `DynamicFrame` appelée `mapped_with_string` avec le schéma et les entrées suivantes.

Notez le champ nommé `AddressString`. Il s'agit du champ sur lequel l'exemple effectue une opération `unbox` en un champ `struct`.

```
root
|-- Average Total Payments: string
|-- AddressString: string
|-- Average Covered Charges: string
|-- DRG Definition: string
|-- Average Medicare Payments: string
|-- Hospital Referral Region Description: string
|-- Address: struct
|   |-- Zip.Code: string
|   |-- City: string
|   |-- Array: array
|   |   |-- element: string
|   |-- State: string
|   |-- Street: string
|-- Provider Id: string
|-- Total Discharges: string
|-- Provider Name: string

+-----+-----+-----+
+-----+-----+-----+
+-----+-----+-----+
|Average Total Payments|   AddressString|Average Covered Charges|   DRG
|Definition|Average Medicare Payments|Hospital Referral Region Description|
|Address|Provider Id|Total Discharges|   Provider Name|
+-----+-----+-----+
+-----+-----+-----+
+-----+-----+-----+
```

```
|          $5777.24|{"Street": "1108 ...|          $32963.07|039 -
EXTRACRANIA...|          $4763.73|          AL - Dothan|[36301,
DOTHAN, [...|          10001|          91|SOUTHEAST ALABAMA...|
|          $5787.57|{"Street": "2505 ...|          $15131.85|039 -
EXTRACRANIA...|          $4976.71|          AL - Birmingham|[35957,
BOAZ, [25...|          10005|          14|MARSHALL MEDICAL ...|
|          $5434.95|{"Street": "205 M...|          $37560.37|039 -
EXTRACRANIA...|          $4453.79|          AL - Birmingham|[35631,
FLORENCE,...|          10006|          24|ELIZA COFFEE MEMO...|
|          $5417.56|{"Street": "50 ME...|          $13998.28|039 -
EXTRACRANIA...|          $4129.16|          AL - Birmingham|[35235,
BIRMINGHA...|          10011|          25| ST VINCENT'S EAST|
...

```

Exemple de code

```
# Example: Use unbox to unbox a string field
# into a struct in a DynamicFrame

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

unboxed = mapped_with_string.unbox("AddressString", "json")
unboxed.printSchema()
unboxed.toDF().show()

```

Sortie

```
root
|-- Average Total Payments: string
|-- AddressString: struct
|   |-- Street: string
|   |-- City: string
|   |-- State: string
|   |-- Zip.Code: string
|   |-- Array: array
|       |-- element: string
|-- Average Covered Charges: string

```

```

|-- DRG Definition: string
|-- Average Medicare Payments: string
|-- Hospital Referral Region Description: string
|-- Address: struct
|   |-- Zip.Code: string
|   |-- City: string
|   |-- Array: array
|   |   |-- element: string
|   |-- State: string
|   |-- Street: string
|-- Provider Id: string
|-- Total Discharges: string
|-- Provider Name: string

+-----+-----+-----+
+-----+-----+-----+
+-----+-----+-----+
|Average Total Payments|      AddressString|Average Covered Charges|      DRG
|Definition|Average Medicare Payments|Hospital Referral Region Description|
|Address|Provider Id|Total Discharges|      Provider Name|
+-----+-----+-----+
+-----+-----+-----+
+-----+-----+-----+
|          $5777.24|[1108 ROSS CLARK ...|          $32963.07|039 -
EXTRACRANIA...|          $4763.73|          AL - Dothan|[36301,
DOTHAN, [...] 10001|          91|SOUTHEAST ALABAMA...|
|          $5787.57|[2505 U S HIGHWAY...|          $15131.85|039 -
EXTRACRANIA...|          $4976.71|          AL - Birmingham|[35957,
BOAZ, [25...] 10005|          14|MARSHALL MEDICAL ...|
|          $5434.95|[205 MARENGO STRE...|          $37560.37|039 -
EXTRACRANIA...|          $4453.79|          AL - Birmingham|[35631,
FLORENCE,...| 10006|          24|ELIZA COFFEE MEMO...|
|          $5417.56|[50 MEDICAL PARK ...|          $13998.28|039 -
EXTRACRANIA...|          $4129.16|          AL - Birmingham|[35235,
BIRMINGHA...| 10011|          25|  ST VINCENT'S EAST|
|          $5658.33|[1000 FIRST STREE...|          $31633.27|039 -
EXTRACRANIA...|          $4851.44|          AL - Birmingham|[35007,
ALABASTER...| 10016|          18|SHELBY BAPTIST ME...|
|          $6653.80|[2105 EAST SOUTH ...|          $16920.79|039 -
EXTRACRANIA...|          $5374.14|          AL - Montgomery|[36116,
MONTGOMER...| 10023|          67|BAPTIST MEDICAL C...|
|          $5834.74|[2000 PEPPERELL P...|          $11977.13|039 -
EXTRACRANIA...|          $4761.41|          AL - Birmingham|[36801,
OPELIKA, ...| 10029|          51|EAST ALABAMA MEDI...|

```

```

|           $8031.12|[619 SOUTH 19TH S...|           $35841.09|039 -
EXTRACRANIA...|           $5858.50|           AL - Birmingham|[35233,
BIRMINGHA...|           10033|           32|UNIVERSITY OF ALA...|
|           $6113.38|[101 SIVLEY RD, H...|           $28523.39|039 -
EXTRACRANIA...|           $5228.40|           AL - Huntsville|[35801,
HUNTSVILL...|           10039|           135| HUNTSVILLE HOSPITAL|
|           $5541.05|[1007 GOODYEAR AV...|           $75233.38|039 -
EXTRACRANIA...|           $4386.94|           AL - Birmingham|[35903,
GADSDEN, ...|           10040|           34|GADSDEN REGIONAL ...|
|           $5461.57|[600 SOUTH THIRD ...|           $67327.92|039 -
EXTRACRANIA...|           $4493.57|           AL - Birmingham|[35901,
GADSDEN, ...|           10046|           14|RIVERVIEW REGIONA...|
|           $5356.28|[4370 WEST MAIN S...|           $39607.28|039 -
EXTRACRANIA...|           $4408.20|           AL - Dothan|[36305,
DOTHAN, [...|           10055|           45|   FLOWERS HOSPITAL|
|           $5374.65|[810 ST VINCENT'S...|           $22862.23|039 -
EXTRACRANIA...|           $4186.02|           AL - Birmingham|[35205,
BIRMINGHA...|           10056|           43|ST VINCENT'S BIRM...|
|           $5366.23|[400 EAST 10TH ST...|           $31110.85|039 -
EXTRACRANIA...|           $4376.23|           AL - Birmingham|[36207,
ANNISTON,...|           10078|           21|NORTHEAST ALABAMA...|
|           $5282.93|[1613 NORTH MCKEN...|           $25411.33|039 -
EXTRACRANIA...|           $4383.73|           AL - Mobile|[36535,
FOLEY, [1...|           10083|           15|SOUTH BALDWIN REG...|
|           $5676.55|[1201 7TH STREET ...|           $9234.51|039 -
EXTRACRANIA...|           $4509.11|           AL - Huntsville|[35609,
DECATUR, ...|           10085|           27|DECATUR GENERAL H...|
|           $5930.11|[6801 AIRPORT BOU...|           $15895.85|039 -
EXTRACRANIA...|           $3972.85|           AL - Mobile|[36608,
MOBILE, [...|           10090|           27| PROVIDENCE HOSPITAL|
|           $6192.54|[809 UNIVERSITY B...|           $19721.16|039 -
EXTRACRANIA...|           $5179.38|           AL - Tuscaloosa|[35401,
TUSCALOOS...|           10092|           31|D C H REGIONAL ME...|
|           $4968.00|[750 MORPHY AVENU...|           $10710.88|039 -
EXTRACRANIA...|           $3898.88|           AL - Mobile|[36532,
FAIRHOPE,...|           10100|           18|   THOMAS HOSPITAL|
|           $5996.00|[701 PRINCETON AV...|           $51343.75|039 -
EXTRACRANIA...|           $4962.45|           AL - Birmingham|[35211,
BIRMINGHA...|           10103|           33|BAPTIST MEDICAL C...|
+-----+-----+-----+-----+
+-----+-----+-----+-----+
+-----+-----+-----+-----+
only showing top 20 rows

```

union

```
union(frame1, frame2, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)
```

Union 2 DynamicFrames. Renvoie DynamicFrame tous les enregistrements des deux entrées DynamicFrames. Cette transformation peut renvoyer des résultats différents à partir de l'union de deux DataFrames avec des données équivalentes. Si vous avez besoin du comportement DataFrame syndical de Spark, pensez à utiliser `toDF`.

- `frame1`— D'abord DynamicFrame à se syndiquer.
- `frame2`— Après DynamicFrame l'union.
- `transformation_ctx` : (facultatif) chaîne unique utilisée pour identifier les informations sur l'état/les statistiques.
- `info` : (facultatif) chaîne à associer à des erreurs dans la transformation.
- `stageThreshold` : (facultatif) nombre maximum d'erreurs dans la transformation jusqu'à ce que le traitement entraîne une erreur
- `totalThreshold` : (facultatif) nombre maximum d'erreurs au total jusqu'à ce que le traitement entraîne une erreur.

unnest

```
unnest(transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)
```

Désimbrique les objets imbriqués dans une image DynamicFrame. Ils deviennent des objets de niveau supérieur et l'opération renvoie une nouvelle image DynamicFrame non imbriquée.

- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).
- `stageThreshold` – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'erreur générée par le processus (facultatif) La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.

- `totalThreshold` – Nombre d'erreurs rencontrées jusqu'à cette transformation, incluse, et qui doit entraîner l'arrêt du processus (facultatif). La valeur par défaut est zéro, ce qui indique que le processus ne doit pas générer d'erreur.

Exemple : utiliser la méthode `unnest` pour transformer des champs imbriqués en champs de niveau supérieur

Cet exemple de code utilise la méthode `unnest` pour aplatir tous les champs imbriqués dans une image `DynamicFrame` en champs de niveau supérieur.

Exemple de jeu de données

L'exemple utilise une image `DynamicFrame` appelée `mapped_medicare` avec le schéma suivant. Notez que le champ `Address` est le seul qui contient des données imbriquées.

```
root
|-- Average Total Payments: string
|-- Average Covered Charges: string
|-- DRG Definition: string
|-- Average Medicare Payments: string
|-- Hospital Referral Region Description: string
|-- Address: struct
|   |-- Zip.Code: string
|   |-- City: string
|   |-- Array: array
|   |   |-- element: string
|   |-- State: string
|   |-- Street: string
|-- Provider Id: string
|-- Total Discharges: string
|-- Provider Name: string
```

Exemple de code

```
# Example: Use unnest to unnest nested
# objects in a DynamicFrame

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
```

```
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Unnest all nested fields
unnested = mapped_medicare.unnest()
unnested.printSchema()
```

Sortie

```
root
|-- Average Total Payments: string
|-- Average Covered Charges: string
|-- DRG Definition: string
|-- Average Medicare Payments: string
|-- Hospital Referral Region Description: string
|-- Address.Zip.Code: string
|-- Address.City: string
|-- Address.Array: array
|   |-- element: string
|-- Address.State: string
|-- Address.Street: string
|-- Provider Id: string
|-- Total Discharges: string
|-- Provider Name: string
```

unnest_ddb_json

Supprime l'imbrication des colonnes imbriquées dans un `DynamicFrame` qui se trouvent spécifiquement dans la structure JSON DynamoDB, et renvoie une nouvelle version non imbriquée `DynamicFrame`. Les colonnes d'un tableau de types de structure ne seront pas non-imbriquées. Notez qu'il s'agit d'un type spécifique de transformation non imbriquée qui se comporte différemment de la transformation `unnest` normale et nécessite que les données soient déjà dans la structure JSON DynamoDB. Pour plus d'informations, consultez [JSON DynamoDB](#).

unnest_ddb_json(transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)

- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne à associer avec le signalement des erreurs pour cette transformation (facultatif).

- `stageThreshold` – Nombre d'erreurs rencontrées pendant cette transformation et qui doit entraîner l'arrêt du processus (facultatif : zéro par défaut, qui indique que le processus ne doit pas être arrêté dans ce cas).
- `totalThreshold` – Nombre d'erreurs rencontrées jusqu'à cette transformation, incluse, et qui doit entraîner l'arrêt du processus (facultatif : zéro par défaut, qui indique que le processus ne doit pas être arrêté dans ce cas).

Par exemple, le schéma d'une lecture d'exportation avec la structure JSON DynamoDB pourrait ressembler à ce qui suit :

```
root
|-- Item: struct
|   |-- ColA: struct
|   |   |-- S: string
|   |-- ColB: struct
|   |   |-- S: string
|   |-- ColC: struct
|   |   |-- N: string
|   |-- ColD: struct
|   |   |-- L: array
|   |   |   |-- element: null
```

La transformation `unnest_ddb_json()` convertirait ceci en :

```
root
|-- ColA: string
|-- ColB: string
|-- ColC: string
|-- ColD: array
|   |-- element: null
```

L'exemple de code suivant montre comment utiliser le connecteur d'exportation AWS Glue DynamoDB, appeler un DynamoDB JSON `unnest` et imprimer le nombre de partitions :

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions
```



```
args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dynamicFrame = glue_context.create_dynamic_frame.from_options(
    connection_type="dynamodb",
    connection_options={
        "dynamodb.export": "ddb",
        "dynamodb.tableArn": "<test_source>",
        "dynamodb.s3.bucket": "<bucket name>",
        "dynamodb.s3.prefix": "<bucket prefix>",
        "dynamodb.s3.bucketOwner": "<account_id>",
    }
)
unnested = dynamicFrame.unnest_ddb_json()
print(unnested.getNumPartitions())

job.commit()
```

write

write(connection_type, connection_options, format, format_options, accumulator_size)

Permet d'obtenir un [DataSink\(objet\)](#) du type de connexion spécifié à partir du [GlueContext classe](#) de ce type DynamicFrame, et l'utilise pour formater et écrire le contenu de ce DynamicFrame. Renvoie le nouveau DynamicFrame formaté et écrit comme spécifié.

- **connection_type** – type de connexion à utiliser. Les valeurs valides sont s3, mysql, postgresql, redshift, sqlserver et oracle.
- **connection_options** – option de connexion à utiliser (facultatif). Pour un **connection_type** de s3, un chemin Amazon S3 est défini.

```
connection_options = {"path": "s3://aws-glue-target/temp"}
```

Pour les connexions JDBC, plusieurs propriétés doivent être définies. Notez que le nom de base de données doit être inclus dans l'URL. Il peut éventuellement être inclus dans les options de connexion.

⚠ Warning

Il n'est pas recommandé de stocker des mots de passe dans votre script. Envisagez de les utiliser boto3 pour les récupérer depuis AWS Secrets Manager le catalogue de données AWS Glue.

```
connection_options = {"url": "jdbc-url/database", "user": "username",  
  "password": passwordVariable, "dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

- `format` – spécification de format (facultatif). Il est utilisé pour un Amazon Simple Storage Service (Amazon S3) ou un AWS Glue connexion qui prend en charge plusieurs formats. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- `format_options` – options de format pour le format spécifié. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- `accumulator_size` : la taille accumulable à utiliser, en octets (facultatif).

– erreurs –

- [assertErrorThreshold](#)
- [errorsAsDynamicChâssis](#)
- [errorsCount](#)
- [stageErrorsCount](#)

`assertErrorThreshold`

`assertErrorThreshold( )` – Assertion pour les erreurs dans les transformations ayant créé ce `DynamicFrame`. Renvoie un `Exception` du `DataFrame` sous-jacent.

`errorsAsDynamicChâssis`

`errorsAsDynamicFrame( )` – Renvoie un `DynamicFrame` dans lequel des enregistrements d'erreur sont imbriqués.

Exemple : utilisez `errorsAsDynamicFrame` pour afficher les enregistrements d'erreurs

L'exemple de code suivant illustre comment utiliser `errorsAsDynamicFrame` méthode pour afficher un enregistrement d'erreur pour un `DynamicFrame`.

Exemple de jeu de données

L'exemple utilise l'ensemble de données suivant que vous pouvez charger sur Amazon S3 au format JSON. Notez que le deuxième enregistrement est mal formé. Les données mal formées interrompent généralement l'analyse des fichiers lorsque vous utilisez SparkSQL. Cependant, `DynamicFrame` reconnaît les problèmes de malformation et transforme les lignes mal formées en enregistrements d'erreurs que vous pouvez gérer individuellement.

```
{"id": 1, "name": "george", "surname": "washington", "height": 178}
{"id": 2, "name": "benjamin", "surname": "franklin",
{"id": 3, "name": "alexander", "surname": "hamilton", "height": 171}
{"id": 4, "name": "john", "surname": "jay", "height": 190}
```

Exemple de code

```
# Example: Use errorsAsDynamicFrame to view error records.
# Replace s3://DOC-EXAMPLE-S3-BUCKET/error_data.json with your location.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Create errors DynamicFrame, view schema
errors = glueContext.create_dynamic_frame.from_options(
    "s3", {"paths": [s3://DOC-EXAMPLE-S3-BUCKET/error_data.json]}, "json"
)
print("Schema of errors DynamicFrame:")
errors.printSchema()

# Show that errors only contains valid entries from the dataset
print("errors contains only valid records from the input dataset (2 of 4 records)")
errors.toDF().show()

# View errors
```

```

print("Errors count:", str(errors.errorsCount()))
print("Errors:")
errors.errorsAsDynamicFrame().toDF().show()

# View error fields and error data
error_record = errors.errorsAsDynamicFrame().toDF().head()

error_fields = error_record["error"]
print("Error fields: ")
print(error_fields.asDict().keys())

print("\nError record data:")
for key in error_fields.asDict().keys():
    print("\n", key, ": ", str(error_fields[key]))

```

Sortie

Schema of errors DynamicFrame:

```

root
|-- id: int
|-- name: string
|-- surname: string
|-- height: int

```

errors contains only valid records from the input dataset (2 of 4 records)

```

+---+-----+-----+-----+
| id|  name|  surname|height|
+---+-----+-----+-----+
|  1|george|washington|  178|
|  4|  john|      jay|  190|
+---+-----+-----+-----+

```

Errors count: 1

Errors:

```

+-----+
|          error|
+-----+
|[[  File "/tmp/20...|
+-----+

```

Error fields:

```

dict_keys(['callsite', 'msg', 'stackTrace', 'input', 'bytesread', 'source',
'dynamicRecord'])

```

Error record data:

```
callsite : Row(site=' File "/tmp/2060612586885849088", line 549, in <module>\n
sys.exit(main())\n File "/tmp/2060612586885849088", line 523, in main\n response
= handler(content)\n File "/tmp/2060612586885849088", line 197, in execute_request
\n result = node.execute()\n File "/tmp/2060612586885849088", line 103, in
execute\n exec(code, global_dict)\n File "<stdin>", line 10, in <module>\n
File "/opt/amazon/lib/python3.6/site-packages/aws glue/dynamicframe.py", line 625, in
from_options\n format_options, transformation_ctx, push_down_predicate, **kwargs)\n
File "/opt/amazon/lib/python3.6/site-packages/aws glue/context.py", line 233, in
create_dynamic_frame_from_options\n source.setFormat(format, **format_options)\n',
info='')
```

msg : error in jackson reader

```
stackTrace : com.fasterxml.jackson.core.JsonParseException: Unexpected character
('{ ' (code 123)): was expecting either valid name character (for unquoted name) or
double-quote (for quoted) to start field name
at [Source: com.amazonaws.services.glue.readers.BufferedStream@73492578; line: 3,
column: 2]
at com.fasterxml.jackson.core.JsonParser._constructError(JsonParser.java:1581)
at
com.fasterxml.jackson.core.base.ParserMinimalBase._reportError(ParserMinimalBase.java:533)
at
com.fasterxml.jackson.core.base.ParserMinimalBase._reportUnexpectedChar(ParserMinimalBase.java:
at
com.fasterxml.jackson.core.json.UTF8StreamJsonParser._handleOddName(UTF8StreamJsonParser.java:
at
com.fasterxml.jackson.core.json.UTF8StreamJsonParser._parseName(UTF8StreamJsonParser.java:1650)
at
com.fasterxml.jackson.core.json.UTF8StreamJsonParser.nextToken(UTF8StreamJsonParser.java:740)
at com.amazonaws.services.glue.readers.JacksonReader$$anonfun$hasNextGoodToken
$1.apply(JacksonReader.scala:57)
at com.amazonaws.services.glue.readers.JacksonReader$$anonfun$hasNextGoodToken
$1.apply(JacksonReader.scala:57)
at scala.collection.Iterator$$anon$9.next(Iterator.scala:162)
at scala.collection.Iterator$$anon$16.hasNext(Iterator.scala:599)
at scala.collection.Iterator$$anon$16.hasNext(Iterator.scala:598)
at scala.collection.Iterator$class.foreach(Iterator.scala:891)
at scala.collection.AbstractIterator.foreach(Iterator.scala:1334)
at com.amazonaws.services.glue.readers.JacksonReader$$anonfun
$1.apply(JacksonReader.scala:120)
```

```

    at com.amazonaws.services.glue.readers.JacksonReader$$$anonfun
$1.apply(JacksonReader.scala:116)
    at
com.amazonaws.services.glue.DynamicRecordBuilder.handleError(DynamicRecordBuilder.scala:209)
    at
com.amazonaws.services.glue.DynamicRecordBuilder.handleErrorWithException(DynamicRecordBuilder
    at
com.amazonaws.services.glue.readers.JacksonReader.nextFailSafe(JacksonReader.scala:116)
    at com.amazonaws.services.glue.readers.JacksonReader.next(JacksonReader.scala:109)
    at com.amazonaws.services.glue.readers.JSONReader.next(JSONReader.scala:247)
    at
com.amazonaws.services.glue.hadoop.TapeHadoopRecordReaderSplittable.nextKeyValue(TapeHadoopRec
    at org.apache.spark.rdd.NewHadoopRDD$$$anon$1.hasNext(NewHadoopRDD.scala:230)
    at org.apache.spark.InterruptibleIterator.hasNext(InterruptibleIterator.scala:37)
    at scala.collection.Iterator$$$anon$11.hasNext(Iterator.scala:409)
    at scala.collection.Iterator$$$anon$11.hasNext(Iterator.scala:409)
    at scala.collection.Iterator$$$anon$13.hasNext(Iterator.scala:462)
    at scala.collection.Iterator$$$anon$11.hasNext(Iterator.scala:409)
    at scala.collection.Iterator$$$anon$11.hasNext(Iterator.scala:409)
    at scala.collection.Iterator$$$anon$13.hasNext(Iterator.scala:462)
    at scala.collection.Iterator$$$anon$11.hasNext(Iterator.scala:409)
    at scala.collection.Iterator$$$anon$11.hasNext(Iterator.scala:409)
    at org.apache.spark.sql.execution.SparkPlan$$$anonfun$2.apply(SparkPlan.scala:255)
    at org.apache.spark.sql.execution.SparkPlan$$$anonfun$2.apply(SparkPlan.scala:247)
    at org.apache.spark.rdd.RDD$$$anonfun$mapPartitionsInternal$1$$$anonfun$apply
$24.apply(RDD.scala:836)
    at org.apache.spark.rdd.RDD$$$anonfun$mapPartitionsInternal$1$$$anonfun$apply
$24.apply(RDD.scala:836)
    at org.apache.spark.rdd.MapPartitionsRDD.compute(MapPartitionsRDD.scala:52)
    at org.apache.spark.rdd.RDD.computeOrReadCheckpoint(RDD.scala:324)
    at org.apache.spark.rdd.RDD.iterator(RDD.scala:288)
    at org.apache.spark.rdd.MapPartitionsRDD.compute(MapPartitionsRDD.scala:52)
    at org.apache.spark.rdd.RDD.computeOrReadCheckpoint(RDD.scala:324)
    at org.apache.spark.rdd.RDD.iterator(RDD.scala:288)
    at org.apache.spark.scheduler.ResultTask.runTask(ResultTask.scala:90)
    at org.apache.spark.scheduler.Task.run(Task.scala:121)
    at org.apache.spark.executor.Executor$TaskRunner$$$anonfun$10.apply(Executor.scala:408)
    at org.apache.spark.util.Utils$.tryWithSafeFinally(Utils.scala:1360)
    at org.apache.spark.executor.Executor$TaskRunner.run(Executor.scala:414)
    at java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1149)
    at java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:624)
    at java.lang.Thread.run(Thread.java:750)

```

```
input :  
  
bytesread : 252  
  
source :  
  
dynamicRecord : Row(id=2, name='benjamin', surname='franklin')
```

errorsCount

`errorsCount( )` – Renvoie le nombre total d'erreurs dans un `DynamicFrame`.

stageErrorsCount

`stageErrorsCount` – Renvoie le nombre d'erreurs survenues lors du processus de génération de ce `DynamicFrame`.

`DynamicFrameCollection` classe

Un `DynamicFrameCollection` est un dictionnaire d'objets [DynamicFrame classe](#) dans lequel les clés sont les noms des `DynamicFrames` et les valeurs, les objets `DynamicFrame`.

`__init__`

`__init__(dynamic_frames, glue_ctx)`

- `dynamic_frames` – Dictionnaire d'objets [DynamicFrame classe](#).
- `glue_ctx` – Un objet [GlueContext classe](#).

Clés

`keys( )` – Renvoie une liste des clés de cette collection, qui comprend généralement les noms des valeurs `DynamicFrame` correspondantes.

Valeurs

`values(key)` – Renvoie une liste des valeurs `DynamicFrame` de cette collection.

Select

select(key)

Renvoie le `DynamicFrame` correspondant à la clé spécifiée (il s'agit généralement du nom du `DynamicFrame`).

- `key` - Clé du `DynamicFrameCollection`, qui représente généralement le nom d'un `DynamicFrame`.

Map

map(callable, transformation_ctx="")

Utilise une fonction transmise pour créer et renvoyer un nouveau `DynamicFrameCollection` basé sur le `DynamicFrames` de cette collection.

- `callable` - Fonction qui utilise un `DynamicFrame` et le contexte de transformation en tant que paramètres et renvoie un `DynamicFrame`.
- `transformation_ctx` - Contexte de transformation utilisé par l'élément callable (facultatif).

FlatMap

flatmap(f, transformation_ctx="")

Utilise une fonction transmise pour créer et renvoyer un nouveau `DynamicFrameCollection` basé sur le `DynamicFrames` de cette collection.

- `f` - Fonction qui utilise un `DynamicFrame` en tant que paramètre et renvoie un `DynamicFrame` ou un `DynamicFrameCollection`.
- `transformation_ctx` - Contexte de transformation utilisé par la fonction (facultatif).

DynamicFrameWriter classe

Méthodes

- [`\_\_init\_\_`](#)
- [`from\_options`](#)
- [`from\_catalog`](#)

- [from_jdbc_conf](#)

`__init__`

`__init__(glue_context)`

- `glue_context` – [GlueContext classe](#) à utiliser.

`from_options`

`from_options(frame, connection_type, connection_options={}, format=None, format_options={}, transformation_ctx="")`

Écrit un `DynamicFrame` à l'aide de la connexion et du format spécifiés.

- `frame` – Objet `DynamicFrame` à écrire.
- `connection_type` – type de connexion. Les valeurs valides sont `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver` et `oracle`.
- `connection_options` – Options de connexion, telles que le chemin et la table de base de données (facultatif). Pour un `connection_type` de `s3`, un chemin Amazon S3 est défini.

```
connection_options = {"path": "s3://aws-glue-target/temp"}
```

Pour les connexions JDBC, plusieurs propriétés doivent être définies. Notez que le nom de base de données doit être inclus dans l'URL. Il peut éventuellement être inclus dans les options de connexion.

Warning

Il n'est pas recommandé de stocker des mots de passe dans votre script. Envisagez de les utiliser `boto3` pour les extraire AWS Secrets Manager du catalogue de données AWS Glue.

```
connection_options = {"url": "jdbc-url/database", "user": "username",  
  "password": passwordVariable, "dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

La propriété `dbtable` est le nom de la table JDBC. Pour les magasins de données JDBC qui prennent en charge les schémas dans une base de données, spécifiez `schema.table-name`. Si aucun schéma n'est fourni, c'est le schéma « public » par défaut qui est utilisé.

Pour plus d'informations, consultez [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#).

- `format` – spécification de format (facultatif). Il est utilisé pour un Amazon Simple Storage Service (Amazon S3) ou un AWS Glue connexion qui prend en charge plusieurs formats. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- `format_options` – options de format pour le format spécifié. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).

`from_catalog`

```
from_catalog(frame, name_space, table_name, redshift_tmp_dir="",  
transformation_ctx="")
```

Écrit un `DynamicFrame` à l'aide de la base de données et du nom de table du catalogue spécifié.

- `frame` – Objet `DynamicFrame` à écrire.
- `name_space` – Base de données à utiliser.
- `table_name` – `table_name` à utiliser.
- `redshift_tmp_dir` – répertoire Amazon Redshift temporaire à utiliser (facultatif).
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `additional_options`— Des options supplémentaires sont proposées à AWS Glue.

Pour écrire à Lake Formation tables régies, vous pouvez utiliser les options supplémentaires suivantes :

- `transactionId`— (Chaîne) ID de transaction auquel effectuer l'écriture dans la table régie. Cette transaction ne peut pas être déjà validée ou interrompue, sinon l'écriture échouera.
- `callDeleteObjectsOnCancel` — (Booléen, facultatif) S'il est défini sur `true` (par défaut), AWS Glue appelle automatiquement l'`DeleteObjectsOnCancelAPI` une fois que l'objet a été

écrit sur Amazon S3. Pour plus d'informations, consultez [DeleteObjectsOnCancel](#) dans le Guide du développeur AWS Lake Formation .

Exemple Exemple : écriture dans une table gouvernée dans Lake Formation

```
txId = glueContext.start_transaction(read_only=False)
glueContext.write_dynamic_frame.from_catalog(
    frame=dyf,
    database = db,
    table_name = tbl,
    transformation_ctx = "datasource0",
    additional_options={"transactionId":txId})
...
glueContext.commit_transaction(txId)
```

from_jdbc_conf

**from_jdbc_conf(frame, catalog_connection, connection_options={},
redshift_tmp_dir = "", transformation_ctx="")**

Écrit un DynamicFrame à l'aide des informations de connexion JDBC spécifiées.

- **frame** – Objet DynamicFrame à écrire.
- **catalog_connection** – Connexion de catalogue à utiliser.
- **connection_options** – Options de connexion, telles que le chemin et la table de base de données (facultatif).
- **redshift_tmp_dir** – répertoire Amazon Redshift temporaire à utiliser (facultatif).
- **transformation_ctx** – Contexte de transformation à utiliser (facultatif).

Exemple pour write_dynamic_frame

Cet exemple écrit la sortie localement en utilisant un **connection_type** de S3 avec un argument de chemin POSIX dans **connection_options**, ce qui permet d'écrire dans le stockage local.

```
glueContext.write_dynamic_frame.from_options(\
    frame = dyf_splitFields,\
    connection_options = {'path': '/home/glue/GlueLocalOutput/'},\
    connection_type = 's3',\
```

```
format = 'json')
```

DynamicFrameReader classe

– méthodes –

- [`\_\_init\_\_`](#)
- [`from\_rdd`](#)
- [`from\_options`](#)
- [`from\_catalog`](#)

`__init__`

`__init__(glue_context)`

- `glue_context` – [GlueContext classe](#) à utiliser.

`from_rdd`

`from_rdd(data, name, schema=None, sampleRatio=None)`

Lit un `DynamicFrame` à partir d'un RDD (Resilient Distributed Dataset).

- `data` – Ensemble de données à partir duquel lire.
- `name` – Nom à partir duquel lire.
- `schema` – Schéma à lire (facultatif).
- `sampleRatio` – Exemple de ratio (facultatif).

`from_options`

`from_options(connection_type, connection_options={}, format=None, format_options={}, transformation_ctx="")`

Lit un `DynamicFrame` à l'aide de la connexion et du format spécifiés.

- `connection_type` – type de connexion. Les valeurs valides sont les suivantes : `s3 mysql postgresql redshift, sqlserver, oracle, dynamodb, etsnowflake`.

- `connection_options` – Options de connexion, telles que le chemin et la table de base de données (facultatif). Pour plus d'informations, consultez la section [Types de connexion et options pour l'ETL dans AWS Glue for Spark](#). Pour un `connection_type` de `s3`, les chemins Amazon S3 sont définis dans un tableau.

```
connection_options = {"paths": [ "s3://amzn-s3-demo-bucket/object_a", "s3://amzn-s3-demo-bucket/object_b"]}
```

Pour les connexions JDBC, plusieurs propriétés doivent être définies. Notez que le nom de base de données doit être inclus dans l'URL. Il peut éventuellement être inclus dans les options de connexion.

 Warning

Il n'est pas recommandé de stocker des mots de passe dans votre script. Envisagez de les utiliser `boto3` pour les récupérer depuis AWS Secrets Manager le catalogue de données AWS Glue.

```
connection_options = {"url": "jdbc-url/database", "user": "username",  
  "password": passwordVariable, "dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

Pour une connexion JDBC qui effectue des lectures parallèles, vous pouvez définir l'option `hashfield`. Par exemple :

```
connection_options = {"url": "jdbc-url/database", "user": "username",  
  "password": passwordVariable, "dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path",  
  "hashfield": "month"}
```

Pour de plus amples informations, veuillez consulter [Lecture en parallèle à partir de tables JDBC](#).

- `format` – spécification de format (facultatif). Il est utilisé pour un Amazon Simple Storage Service (Amazon S3) ou un AWS Glue connexion qui prend en charge plusieurs formats. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.

- `format_options` – options de format pour le format spécifié. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `push_down_predicate` – filtre les partitions sans avoir à répertorier ni lire tous les fichiers de votre jeu de données. Pour plus d'informations, consultez [Pre-Filtering Using Pushdown Predicates](#).

`from_catalog`

```
from_catalog(database, table_name, redshift_tmp_dir="",  
transformation_ctx="", push_down_predicate="", additional_options={})
```

Lit un `DynamicFrame` à l'aide de l'espace de noms et du nom de table du catalogue spécifié.

- `database` – Base de données à partir de laquelle lire.
- `table_name` – Nom de la table à partir de laquelle lire.
- `redshift_tmp_dir` – répertoire Amazon Redshift temporaire à utiliser (facultatif s'il ne lit pas les données provenant de Redshift).
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `push_down_predicate` – filtre les partitions sans avoir à répertorier ni lire tous les fichiers de votre jeu de données. Pour de plus amples informations, veuillez consulter [Préfiltrage à l'aide des prédicats pushdown](#).
- `additional_options`— Des options supplémentaires sont proposées à AWS Glue.
 - Pour utiliser une connexion JDBC qui effectue des lectures parallèles, vous pouvez définir les options `hashfield`, `hashexpression` ou `hashpartitions`. Par exemple :

```
additional_options = {"hashfield": "month"}
```

Pour de plus amples informations, veuillez consulter [Lecture en parallèle à partir de tables JDBC](#).

- Pour passer une expression de catalogue à filtrer en fonction des colonnes d'index, vous pouvez voir l'option `catalogPartitionPredicate`.

`catalogPartitionPredicate` – vous pouvez passer une expression de catalogue à filtrer en fonction des colonnes d'index. Cela envoie le filtrage du côté serveur. Pour de plus amples informations, consultez [AWS Glue Indexes](#) de partition. Notez que `push_down_predicate` et

catalogPartitionPredicate utilisent des syntaxes différentes. Le premier utilise la syntaxe standard SQL Spark et le dernier utilise l'analyseur JSQL.

Pour de plus amples informations, veuillez consulter [Gestion des partitions pour la sortie ETL dans AWS Glue](#).

GlueContext classe

Encapsule l'[SparkContext](#) objet Apache Spark et fournit ainsi des mécanismes permettant d'interagir avec la plateforme Apache Spark.

`__init__`

`__init__(sparkContext)`

- sparkContext – Contexte Apache Spark à utiliser.

Création

- [__init__](#)
- [getSource](#)
- [create_dynamic_frame_from_rdd](#)
- [create_dynamic_frame_from_catalog](#)
- [create_dynamic_frame_from_options](#)
- [create_sample_dynamic_frame_from_catalog](#)
- [create_sample_dynamic_frame_from_options](#)
- [add_ingestion_time_columns](#)
- [create_data_frame_from_catalog](#)
- [create_data_frame_from_options](#)
- [forEachBatch](#)

getSource

`getSource(connection_type, transformation_ctx = "", **options)`

Crée un objet DataSource qui peut être utilisé pour lire DynamicFrames à partir de sources externes.

- `connection_type` – type de connexion à utiliser, tel qu'Amazon Simple Storage Service (Amazon S3), Amazon Redshift et JDBC. Les valeurs valides sont les suivantes : `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle` et `dynamodb`.
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `options` – Ensemble de paires nom-valeur facultatives. Pour plus d'informations, consultez [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#).

Voici un exemple d'utilisation de `getSource`.

```
>>> data_source = context.getSource("file", paths=["/in/path"])
>>> data_source.setFormat("json")
>>> myFrame = data_source.getFrame()
```

`create_dynamic_frame_from_rdd`

`create_dynamic_frame_from_rdd(data, name, schema=None, sample_ratio=None, transformation_ctx="")`

Renvoie un objet `DynamicFrame` créé à partir d'un RDD (Resilient Distributed Dataset) Apache Spark.

- `data` — La source de données à utiliser.
- `name` – Nom des données à utiliser.
- `schema` – Schéma à utiliser (facultatif).
- `sample_ratio` – Exemple de ratio à utiliser (facultatif).
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).

`create_dynamic_frame_from_catalog`

`create_dynamic_frame_from_catalog(database, table_name, redshift_tmp_dir, transformation_ctx = "", push_down_predicate= "", additional_options = {}, catalog_id = None)`

Renvoie un objet `DynamicFrame` créé à l'aide d'un nom de table et de base de données Data Catalog. Lorsque vous utilisez cette méthode, vous fournissez des `format_options` propriétés de table sur la table AWS Glue Data Catalog spécifiée et d'autres options via l'`additional_options` argument.

- `Database` – Base de données à partir de laquelle lire.
- `table_name` – Nom de la table à partir de laquelle lire.
- `redshift_tmp_dir` – répertoire Amazon Redshift temporaire à utiliser (facultatif).
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `push_down_predicate` – filtre les partitions sans avoir à répertorier ni lire tous les fichiers de votre jeu de données. Pour connaître les sources prises en charge et les limites, consultez [Optimisation des lectures avec pushdown dans AWS Glue ETL](#). Pour de plus amples informations, veuillez consulter [Préfiltrage à l'aide des prédicats pushdown](#).
- `additional_options` — Ensemble de paires nom-valeur facultatives. Les options possibles comprennent celles répertoriées dans [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#), sauf pour `endpointUrl`, `streamName`, `bootstrap.servers`, `security.protocol`, `topicName`, `classification` et `delimiter`. Est une autre option prise en charge `catalogPartitionPredicate`:

`catalogPartitionPredicate` – Vous pouvez passer une expression de catalogue à filtrer en fonction des colonnes d'index. Cela envoie le filtrage du côté serveur. Pour en savoir plus, consultez [AWS Glue Indexes de partition](#). Notez que `push_down_predicate` et `catalogPartitionPredicate` utilisent des syntaxes différentes. Le premier utilise la syntaxe standard SQL Spark et le dernier utilise l'analyseur JSQL.

- `catalog_id` – ID du catalogue (ID du compte) Data Catalog auquel vous accédez. Lorsque la valeur est `Aucun`, l'ID de compte par défaut de l'appelant est utilisé.

`create_dynamic_frame_from_options`

`create_dynamic_frame_from_options(connection_type, connection_options={}, format=None, format_options={}, transformation_ctx = "")`

Renvoie un `DynamicFrame` créé avec la connexion et le format spécifiés.

- `connection_type` – type de connexion, tel qu'Amazon S3, Amazon Redshift et JDBC. Les valeurs valides sont les suivantes : `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle` et `dynamodb`.
- `connection_options` – options de connexion, telles que les chemins et la table de base de données (facultatif). Pour un `connection_type` de `s3`, une liste de chemins Amazon S3 est définie.

```
connection_options = {"paths": ["s3://aws-glue-target/temp"]}]}
```

Pour les connexions JDBC, plusieurs propriétés doivent être définies. Notez que le nom de base de données doit être inclus dans l'URL. Il peut éventuellement être inclus dans les options de connexion.

 Warning

Il n'est pas recommandé de stocker des mots de passe dans votre script. Envisagez de les utiliser boto3 pour les extraire AWS Secrets Manager du catalogue de données AWS Glue.

```
connection_options = {"url": "jdbc-url/database", "user": "username",  
  "password": passwordVariable, "dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

La propriété dbtable est le nom de la table JDBC. Pour les magasins de données JDBC qui prennent en charge les schémas dans une base de données, spécifiez schema.table-name. Si aucun schéma n'est fourni, c'est le schéma « public » par défaut qui est utilisé.

Pour de plus amples informations, veuillez consulter [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#).

- `format`— Une spécification de format. Utilisée pour une connexion Amazon S3 ou AWS Glue prenant en charge plusieurs formats. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- `format_options` – options de format pour le format spécifié. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `push_down_predicate` – filtre les partitions sans avoir à répertorier ni lire tous les fichiers de votre jeu de données. Pour connaître les sources prises en charge et les limites, consultez [Optimisation des lectures avec pushdown dans AWS Glue ETL](#). Pour plus d'informations, consultez [Pre-Filtering Using Pushdown Predicates](#).

create_sample_dynamic_frame_from_catalog

```
create_sample_dynamic_frame_from_catalog(database, table_name, num,  
redshift_tmp_dir, transformation_ctx = "", push_down_predicate= "",  
additional_options = {}, sample_options = {}, catalog_id = None)
```

Retourne un objet `DynamicFrame` créé à l'aide d'un nom de tableau et de base de données Data Catalog. Le `DynamicFrame` ne contient que les premiers enregistrements `num` provenant d'une source de données.

- `database` – Base de données à partir de laquelle lire.
- `table_name` – Nom de la table à partir de laquelle lire.
- `num` – Nombre maximal d'enregistrements dans la trame dynamique d'échantillon renvoyée.
- `redshift_tmp_dir` – répertoire Amazon Redshift temporaire à utiliser (facultatif).
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `push_down_predicate` – filtre les partitions sans avoir à répertorier ni lire tous les fichiers de votre jeu de données. Pour plus d'informations, consultez [Préfiltrage à l'aide des prédicats pushdown](#).
- `additional_options` — Ensemble de paires nom-valeur facultatives. Les options possibles comprennent celles répertoriées dans [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#), sauf pour `endpointUrl`, `streamName`, `bootstrap.servers`, `security.protocol`, `topicName`, `classification` et `delimiter`.
- `sample_options` — Paramètres permettant de contrôler le comportement d'échantillonnage (facultatif). Paramètres disponibles actuels pour les sources Amazon S3 :
 - `maxSamplePartitions` — Nombre maximal de partitions que l'échantillonnage lira. Valeur par défaut : 10
 - `maxSampleFilesPerPartition` — Nombre maximal de fichiers que l'échantillonnage lira dans une partition. Valeur par défaut : 10.

Ces paramètres permettent de réduire le temps consommé par la liste des fichiers. Par exemple, supposons que le jeu de données comporte 1 000 partitions et que chaque partition comporte 10 fichiers. Si vous définissez `maxSamplePartitions = 10`, et `maxSampleFilesPerPartition = 10`, au lieu de répertorier les 10 000 fichiers, l'échantillonnage ne listera et ne lira que les 10 premières partitions avec les 10 premiers fichiers de chacun : $10 \times 10 = 100$ au total.

- `catalog_id` – ID du catalogue Data Catalog auquel vous accédez (ID du compte Data Catalog). Valeur définie sur `None` par défaut. `None` correspond par défaut à l'ID de catalogue du compte ayant initié l'appel dans le service.

`create_sample_dynamic_frame_from_options`

```
create_sample_dynamic_frame_from_options(connection_type,  
connection_options={}, num, sample_options={}, format=None,  
format_options={}, transformation_ctx = "")
```

Renvoie un `DynamicFrame` créé avec la connexion et le format spécifiés. Le `DynamicFrame` ne contient que les premiers enregistrements `num` provenant d'une source de données.

- `connection_type` – type de connexion, tel qu'Amazon S3, Amazon Redshift et JDBC. Les valeurs valides sont les suivantes : `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle` et `dynamodb`.
- `connection_options` – options de connexion, telles que les chemins et la table de base de données (facultatif). Pour plus d'informations, consultez [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#).
- `num` – Nombre maximal d'enregistrements dans la trame dynamique d'échantillon renvoyée.
- `sample_options` — Paramètres permettant de contrôler le comportement d'échantillonnage (facultatif). Paramètres disponibles actuels pour les sources Amazon S3 :
 - `maxSamplePartitions` — Nombre maximal de partitions que l'échantillonnage lira. Valeur par défaut : 10
 - `maxSampleFilesPerPartition` — Nombre maximal de fichiers que l'échantillonnage lira dans une partition. Valeur par défaut : 10.

Ces paramètres permettent de réduire le temps consommé par la liste des fichiers. Par exemple, supposons que le jeu de données comporte 1 000 partitions et que chaque partition comporte 10 fichiers. Si vous définissez `maxSamplePartitions = 10`, et `maxSampleFilesPerPartition = 10`, au lieu de répertorier les 10 000 fichiers, l'échantillonnage ne listera et ne lira que les 10 premières partitions avec les 10 premiers fichiers de chacun : $10 \times 10 = 100$ au total.

- `format` — Une spécification de format. Utilisée pour une connexion Amazon S3 ou AWS Glue prenant en charge plusieurs formats. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.

- `format_options` – options de format pour le format spécifié. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `push_down_predicate` – filtre les partitions sans avoir à répertorier ni lire tous les fichiers de votre jeu de données. Pour plus d'informations, consultez [Préfiltrage à l'aide des prédicats pushdown](#).

`add_ingestion_time_columns`

`add_ingestion_time_columns(dataFrame, timeGranularity = "")`

Ajoute des colonnes de temps d'ingestion, telles que `ingest_year`, `ingest_month`, `ingest_day`, `ingest_hour`, `ingest_minute` à l'entrée `DataFrame`. Cette fonction est automatiquement générée dans le script généré par AWS Glue lorsque vous spécifiez une table Data Catalog avec Amazon S3 comme cible. Cette fonction met automatiquement à jour la partition avec les colonnes de temps d'ingestion sur la table de sortie. Cela permet aux données de sortie d'être automatiquement partitionnées à l'heure d'ingestion sans nécessiter de colonnes d'heure d'ingestion explicites dans les données d'entrée.

- `dataFrame` – `dataFrame` auquel ajouter les colonnes de temps d'ingestion.
- `timeGranularity` — granularité des colonnes de temps. Les valeurs valides sont « day », « hour » et « minute ». Par exemple, si « hour » est transmis à la fonction, les colonnes de temps « `ingest_year` », « `ingest_month` », « `ingest_day` » et « `ingest_hour` » seront ajoutées à l'original « `dataFrame` ».

Renvoie le bloc de données après l'ajout des colonnes de granularité temporelle.

Exemple :

```
dynamic_frame = DynamicFrame.fromDF(glueContext.add_ingestion_time_columns(dataFrame,
"hour"))
```

`create_data_frame_from_catalog`

```
create_data_frame_from_catalog(database, table_name, transformation_ctx =  
"", additional_options = {})
```

Renvoie un objet DataFrame créé à l'aide d'un nom de table et de base de données Data Catalog.

- `database` – base de données Data Catalog à lire.
- `table_name` – nom de la table Data Catalog à partir de laquelle lire.
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `additional_options` – Ensemble de paires nom-valeur facultatives. Les options possibles incluent celles répertoriées dans [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#) pour les sources de streaming, telles que `startingPosition`, `maxFetchTimeInMs` et `startingOffsets`.
- `useSparkDataSource`— Lorsque ce paramètre est défini sur `true`, force AWS Glue à utiliser l'API native de source de données Spark pour lire le tableau. L'API Spark Data Source prend en charge les formats suivants : AVRO, binaire, CSV, JSON, ORC, Parquet et texte. Dans une table Data Catalog, vous spécifiez le format à l'aide de la propriété `classification`. Pour en savoir plus sur l'API Spark Data Source, consultez la [documentation officielle d'Apache Spark](#).

L'utilisation de `create_data_frame_from_catalog` avec `useSparkDataSource` offre les avantages suivants :

- Renvoie directement un DataFrame et fournit une alternative à `create_dynamic_frame.from_catalog().toDF()`.
- Prend en charge le contrôle des autorisations AWS Lake Formation au niveau de la table pour les formats natifs.
- Prend en charge la lecture des formats de lacs de données sans contrôle des autorisations AWS Lake Formation au niveau de la table. Pour de plus amples informations, veuillez consulter [Utilisation de frameworks de lacs de données avec des tâches AWS Glue ETL](#).

Lorsque vous l'activez `useSparkDataSource`, vous pouvez également ajouter n'importe laquelle des [options de source de données Spark](#) `additional_options` selon vos besoins. AWS Glue transmet ces options directement au lecteur Spark.

- `useCatalogSchema`— Lorsqu'il est défini sur `true`, AWS Glue applique le schéma du catalogue de données au résultat DataFrame. Sinon, le lecteur déduit le schéma à partir des données. Lorsque vous activez `useCatalogSchema`, vous devez également définir `useSparkDataSource` sur `true`.

Limites

Lorsque vous utilisez l'option `useSparkDataSource`, tenez compte des restrictions suivantes :

- Lorsque vous l'utilisez `useSparkDataSource`, AWS Glue en crée une nouvelle `DataFrame` dans une session Spark distincte, différente de la session Spark d'origine.
- Le filtrage des `DataFrame` partitions Spark ne fonctionne pas avec les fonctionnalités de AWS Glue suivantes.
 - [Signets de tâche](#)
 - [Exclusion des classes de stockage Amazon S3](#)
 - [Prédicats de partition de catalogue](#)

Pour utiliser le filtrage des partitions avec ces fonctionnalités, vous pouvez utiliser le prédicat AWS Glue pushdown. Pour de plus amples informations, veuillez consulter [Préfiltrage à l'aide des prédicats pushdown](#). Le filtrage sur les colonnes non partitionnées n'est pas concerné.

L'exemple de script suivant illustre un filtrage de partition inadéquat à l'aide de l'option `excludeStorageClasses`.

```
// Incorrect partition filtering using Spark filter with excludeStorageClasses
read_df = glueContext.create_data_frame.from_catalog(
    database=database_name,
    table_name=table_name,
    additional_options = {
        "useSparkDataSource": True,
        "excludeStorageClasses" : ["GLACIER", "DEEP_ARCHIVE"]
    }
)

// Suppose year and month are partition keys.
// Filtering on year and month won't work, the filtered_df will still
// contain data with other year/month values.
filtered_df = read_df.filter("year == '2017 and month == '04' and 'state == 'CA'")
```

L'exemple de script suivant illustre l'utilisation adéquate d'un prédicat pushdown dans le cadre d'un filtrage de partition à l'aide de l'option `excludeStorageClasses`.

```
// Correct partition filtering using the AWS Glue pushdown predicate
// with excludeStorageClasses
read_df = glueContext.create_data_frame.from_catalog(
```

```

    database=database_name,
    table_name=table_name,
    // Use AWS Glue pushdown predicate to perform partition filtering
    push_down_predicate = "(year=='2017' and month=='04')"
    additional_options = {
        "useSparkDataSource": True,
        "excludeStorageClasses" : ["GLACIER", "DEEP_ARCHIVE"]
    }
)

// Use Spark filter only on non-partitioned columns
filtered_df = read_df.filter("state == 'CA'")

```

Exemple : Création d'une table CSV à l'aide du lecteur de source de données Spark

```

// Read a CSV table with '\t' as separator
read_df = glueContext.create_data_frame.from_catalog(
    database=<database_name>,
    table_name=<table_name>,
    additional_options = {"useSparkDataSource": True, "sep": '\t'}
)

```

`create_data_frame_from_options`

`create_data_frame_from_options(connection_type, connection_options={}, format=None, format_options={}, transformation_ctx = "")`

Cette API est désormais obsolète. Utilisez plutôt les API `getSource()`. Renvoie un `DataFrame` créé avec la connexion et le format spécifiés. Utilisez cette fonction uniquement avec les sources de streaming AWS Glue.

- `connection_type` – type de connexion en streaming. Les valeurs valides sont `kinesis` et `kafka`.
- `connection_options` – options de connexion, qui sont différentes pour Kinesis et Kafka. Vous trouverez la liste de toutes les options de connexion pour chaque source de données de streaming sur la page [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#). Notez les différences suivantes dans les options de connexion en streaming :
 - Les sources de streaming Kinesis nécessitent `streamARN`, `startingPosition`, `inferSchema` et `classification`.

- Les sources de streaming Kafka nécessitent `connectionName`, `topicName`, `startingOffsets`, `inferSchema` et `classification`.
- `format`— Une spécification de format. Utilisée pour une connexion Amazon S3 ou AWS Glue prenant en charge plusieurs formats. Pour plus d'informations sur les formats pris en charge, consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#).
- `format_options` – options de format pour le format spécifié. Pour de plus amples informations sur les options de formats pris en charge, veuillez consulter [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#).
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).

Exemple pour la source de streaming Amazon Kinesis :

```
kinesis_options =  
    { "streamARN": "arn:aws:kinesis:us-east-2:777788889999:stream/fromOptionsStream",  
      "startingPosition": "TRIM_HORIZON",  
      "inferSchema": "true",  
      "classification": "json"  
    }  
data_frame_datasource0 =  
    glueContext.create_data_frame.from_options(connection_type="kinesis",  
        connection_options=kinesis_options)
```

Exemple pour la source de streaming Kafka :

```
kafka_options =  
    { "connectionName": "ConfluentKafka",  
      "topicName": "kafka-auth-topic",  
      "startingOffsets": "earliest",  
      "inferSchema": "true",  
      "classification": "json"  
    }  
data_frame_datasource0 =  
    glueContext.create_data_frame.from_options(connection_type="kafka",  
        connection_options=kafka_options)
```

forEachBatch

forEachBatch(frame, batch_function, options)

S'applique à `batch_function` transmis à chaque micro-lot lu à partir de la source de streaming.

- `frame`— Le `DataFrame` contenant le micro-lot actuel.
- `batch_function` — fonction qui sera appliquée à chaque micro-lot.
- `options` — collection de paires clé-valeur qui contient des informations sur le traitement de micro-lots. Les options suivantes sont requises :
 - `windowSize` — durée de traitement de chaque lot.
 - `checkpointLocation` — emplacement dans lequel les points de contrôle sont stockés pour la tâche ETL en streaming.
 - `batchMaxRetries` – nombre maximum de nouvelles tentatives pour ce lot en cas d'échec. La valeur par défaut est 3. Cette option n'est configurable que pour Glue version 2.0 et ultérieure.

Exemple :

```
glueContext.forEachBatch(  
    frame = data_frame_datasource0,  
    batch_function = processBatch,  
    options = {  
        "windowSize": "100 seconds",  
        "checkpointLocation": "s3://kafka-auth-dataplane/confluent-test/output/  
checkpoint/"  
    }  
)  
  
def processBatch(data_frame, batchId):  
    if (data_frame.count() > 0):  
        datasource0 = DynamicFrame.fromDF(  
            glueContext.add_ingestion_time_columns(data_frame, "hour"),  
            glueContext, "from_data_frame"  
        )  
        additionalOptions_datasink1 = {"enableUpdateCatalog": True}  
        additionalOptions_datasink1["partitionKeys"] = ["ingest_yr", "ingest_mo",  
"ingest_day"]  
        datasink1 = glueContext.write_dynamic_frame.from_catalog(  
            frame = datasource0,  
            database = "tempdb",
```

```
    table_name = "kafka-auth-table-output",  
    transformation_ctx = "datasink1",  
    additional_options = additionalOptions_datasink1  
)
```

Utilisation des jeux de données dans Amazon S3

- [purge_table](#)
- [purge_s3_path](#)
- [transition_table](#)
- [transition_s3_path](#)

purge_table

purge_table(catalog_id=None, database="", table_name="", options={}, transformation_ctx="")

Supprime les fichiers d'Amazon S3 pour la base de données et la table spécifiés pour le catalogue. Si tous les fichiers d'une partition sont supprimés, cette partition est également éliminée du catalogue. Nous ne prenons pas en charge l'action `purge_table` sur les tables enregistrées auprès de Lake Formation.

Pour pouvoir récupérer des objets supprimés, vous pouvez activer la [gestion des versions d'objet](#) au niveau du compartiment Amazon S3. Lorsqu'un objet est supprimé d'un compartiment pour lequel la gestion des versions d'objet n'est pas activée, il ne peut pas être récupéré. Pour plus d'informations sur la récupération d'objets supprimés dans un compartiment pour lequel la gestion des versions est activée, consultez [Comment récupérer un objet Amazon S3 qui a été supprimé ?](#) dans le Centre de connaissances AWS Support .

- `catalog_id` – ID du catalogue Data Catalog auquel vous accédez (ID du compte Data Catalog). Valeur définie sur `None` par défaut. `None` correspond par défaut à l'ID de catalogue du compte ayant initié l'appel dans le service.
- `database` – Base de données à utiliser.
- `table_name` – nom de la table à utiliser.
- `options` – options destinées au filtrage des fichiers à supprimer et à la génération des fichiers manifestes.

- `retentionPeriod` – spécifie une période de conservation des fichiers, en nombre d'heures. Les dossiers dont la date est postérieure à cette période sont conservés. Par défaut, elle est réglée sur 168 heures (7 jours).
- `partitionPredicate` – les partitions satisfaisant à ce prédicat sont supprimées. Les fichiers qui se situent dans la période de conservation pour ces partitions ne sont pas supprimés. Valeur définie sur "" – vide par défaut.
- `excludeStorageClasses` – les fichiers avec classe de stockage dans le jeu `excludeStorageClasses` ne sont pas supprimés. La valeur par défaut est `Set()` – jeu vide.
- `manifestFilePath` – chemin facultatif pour la génération du fichier manifeste. Tous les fichiers qui ont été purgés avec succès sont enregistrés dans `Success.csv`, et ceux qui ont échoué dans `Failed.csv`.
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif). Utilisé dans le chemin du fichier manifeste.

Exemple

```
glueContext.purge_table("database", "table", {"partitionPredicate": "(month=='march')",  
  "retentionPeriod": 1, "excludeStorageClasses": ["STANDARD_IA"], "manifestFilePath":  
  "s3://bucketmanifest/"})
```

purge_s3_path

purge_s3_path(s3_path, options={}, transformation_ctx="")

Supprime les fichiers du chemin Amazon S3 spécifié de manière récursive.

Pour pouvoir récupérer des objets supprimés, vous pouvez activer la [gestion des versions d'objet](#) au niveau du compartiment Amazon S3. Lorsqu'un objet est supprimé d'un compartiment pour lequel la gestion des versions d'objet n'est pas activée, il ne peut pas être récupéré. Pour plus d'informations sur la façon de récupérer des objets supprimés dans un compartiment avec gestion des versions, consultez [Comment puis-je récupérer un objet Amazon S3 qui a été supprimé ?](#) dans le Support Knowledge Center.

- `s3_path` – chemin Amazon S3 des fichiers à supprimer dans le format `s3://<bucket>/<prefix>/`
- `options` – options destinées au filtrage des fichiers à supprimer et à la génération des fichiers manifestes.

- `retentionPeriod` – spécifie une période de conservation des fichiers, en nombre d'heures. Les dossiers dont la date est postérieure à cette période sont conservés. Par défaut, elle est réglée sur 168 heures (7 jours).
- `excludeStorageClasses` – les fichiers avec classe de stockage dans le jeu `excludeStorageClasses` ne sont pas supprimés. La valeur par défaut est `Set()` – jeu vide.
- `manifestFilePath` – chemin facultatif pour la génération du fichier manifeste. Tous les fichiers qui ont été purgés avec succès sont enregistrés dans `Success.csv`, et ceux qui ont échoué dans `Failed.csv`
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif). Utilisé dans le chemin du fichier manifeste.

Exemple

```
glueContext.purge_s3_path("s3://bucket/path/", {"retentionPeriod": 1,
"excludeStorageClasses": ["STANDARD_IA"], "manifestFilePath": "s3://bucketmanifest/"})
```

`transition_table`

`transition_table(database, table_name, transition_to, options={}, transformation_ctx="", catalog_id=None)`

Transition de la classe de stockage des fichiers stockés sur Amazon S3 pour la base de données et la table spécifiés pour le catalogue.

Vous pouvez effectuer une transition entre deux classes de stockage. Pour les classes de stockage GLACIER et DEEP_ARCHIVE, vous pouvez effectuer la transition vers ces classes. Cependant, vous devez utiliser S3 RESTORE pour effectuer la transition des classes de stockage GLACIER et DEEP_ARCHIVE.

Si vous exécutez des tâches ETL AWS Glue qui lisent des fichiers ou des partitions à partir d'Amazon S3, vous pouvez exclure certains types de classe de stockage Amazon S3. Pour plus d'informations, consultez [Exclusion des classes de stockage Amazon S3](#).

- `database` – Base de données à utiliser.
- `table_name` – nom de la table à utiliser.
- `transition_to` – [classe de stockage Amazon S3](#) vers laquelle effectuer la transition.

- **options** – options destinées au filtrage des fichiers à supprimer et à la génération des fichiers manifestes.
 - **retentionPeriod** – spécifie une période de conservation des fichiers, en nombre d'heures. Les dossiers dont la date est postérieure à cette période sont conservés. Par défaut, elle est réglée sur 168 heures (7 jours).
 - **partitionPredicate** – une transition est effectuée pour les partitions satisfaisant à ce prédicat. Aucune transition n'a lieu pour les fichiers qui se trouvent dans la période de conservation. Valeur définie sur "" – vide par défaut.
 - **excludeStorageClasses** – aucune transition n'a lieu pour les fichiers avec classe de stockage dans le jeu `excludeStorageClasses`. La valeur par défaut est `Set()` – jeu vide.
 - **manifestFilePath** – chemin facultatif pour la génération du fichier manifeste. Tous les fichiers dont la transition a été effectuée avec succès sont enregistrés dans `Success.csv`, et ceux qui ont échoué dans `Failed.csv`
 - **accountId** – ID de compte Amazon Web Services permettant d'exécuter la transformation de la transition. Obligatoire pour cette transformation.
 - **roleArn** – Le AWS rôle d'exécuter la transformation de transition. Obligatoire pour cette transformation.
- **transformation_ctx** – Contexte de transformation à utiliser (facultatif). Utilisé dans le chemin du fichier manifeste.
- **catalog_id** – ID du catalogue Data Catalog auquel vous accédez (ID du compte Data Catalog). Valeur définie sur `None` par défaut. `None` correspond par défaut à l'ID de catalogue du compte ayant initié l'appel dans le service.

Exemple

```
glueContext.transition_table("database", "table", "STANDARD_IA", {"retentionPeriod": 1,
    "excludeStorageClasses": ["STANDARD_IA"], "manifestFilePath": "s3://bucketmanifest/",
    "accountId": "12345678901", "roleArn": "arn:aws:iam::123456789012:user/example-username"})
```

transition_s3_path

```
transition_s3_path(s3_path, transition_to, options={},
transformation_ctx="")
```

Transition récursive de la classe de stockage des fichiers dans le chemin Amazon S3 spécifié.

Vous pouvez effectuer une transition entre deux classes de stockage. Pour les classes de stockage GLACIER et DEEP_ARCHIVE, vous pouvez effectuer la transition vers ces classes. Cependant, vous devez utiliser S3 RESTORE pour effectuer la transition des classes de stockage GLACIER et DEEP_ARCHIVE.

Si vous exécutez des tâches ETL AWS Glue qui lisent des fichiers ou des partitions à partir d'Amazon S3, vous pouvez exclure certains types de classe de stockage Amazon S3. Pour plus d'informations, consultez [Exclusion des classes de stockage Amazon S3](#).

- `s3_path` – chemin Amazon S3 des fichiers à passer au format `s3://<bucket>/<prefix>/`
- `transition_to` – [classe de stockage Amazon S3](#) vers laquelle effectuer la transition.
- `options` – options destinées au filtrage des fichiers à supprimer et à la génération des fichiers manifestes.
 - `retentionPeriod` – spécifie une période de conservation des fichiers, en nombre d'heures. Les dossiers dont la date est postérieure à cette période sont conservés. Par défaut, elle est réglée sur 168 heures (7 jours).
 - `partitionPredicate` – une transition est effectuée pour les partitions satisfaisant à ce prédicat. Aucune transition n'a lieu pour les fichiers qui se trouvent dans la période de conservation. Valeur définie sur "" – vide par défaut.
 - `excludeStorageClasses` – aucune transition n'a lieu pour les fichiers avec classe de stockage dans le jeu `excludeStorageClasses`. La valeur par défaut est `Set()` – jeu vide.
 - `manifestFilePath` – chemin facultatif pour la génération du fichier manifeste. Tous les fichiers dont la transition a été effectuée avec succès sont enregistrés dans `Success.csv`, et ceux qui ont échoué dans `Failed.csv`
 - `accountId` – ID de compte Amazon Web Services permettant d'exécuter la transformation de la transition. Obligatoire pour cette transformation.
 - `roleArn` – Le AWS rôle d'exécuter la transformation de transition. Obligatoire pour cette transformation.
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif). Utilisé dans le chemin du fichier manifeste.

Exemple

```
glueContext.transition_s3_path("s3://bucket/prefix/", "STANDARD_IA",  
    {"retentionPeriod": 1, "excludeStorageClasses": ["STANDARD_IA"],
```

```
"manifestFilePath": "s3://bucketmanifest/", "accountId": "12345678901", "roleArn":  
"arn:aws:iam::123456789012:user/example-username"}))
```

Extraction

- [extract_jdbc_conf](#)

extract_jdbc_conf

extract_jdbc_conf(connection_name, catalog_id = None)

Retourne un dict dont les clés contiennent les propriétés de configuration de l'objet de connexion AWS Glue dans le catalogue de données.

- user – Nom d'utilisateur de la base de données.
- password – Le mot de passe de la base de données.
- vendor – Spécifie un fournisseur (mysql, postgresql, oracle, sqlserver, etc.).
- enforceSSL – Chaîne booléenne indiquant si une connexion sécurisée est requise.
- customJDBCCert – Utilise un certificat client spécifique à partir du chemin Amazon S3 indiqué.
- skipCustomJDBCCertValidation – Chaîne booléenne indiquant si le customJDBCCert doit être validé par une autorité de certification.
- customJDBCCertString – Informations supplémentaires sur le certificat personnalisé, spécifique au type de pilote.
- url – (Obsolète) URL JDBC avec uniquement le protocole, le serveur et le port.
- fullUrl – URL JDBC telle qu'elle a été saisie lors de la création de la connexion (disponible dans la version AWS Glue 3.0 ou ultérieure).

Exemple de récupération de configurations JDBC :

```
jdbc_conf = glueContext.extract_jdbc_conf(connection_name="your_glue_connection_name")  
print(jdbc_conf)  
>>> {'enforceSSL': 'false', 'skipCustomJDBCCertValidation': 'false', 'url':  
    'jdbc:mysql://myserver:3306', 'fullUrl': 'jdbc:mysql://myserver:3306/mydb',  
    'customJDBCCertString': '', 'user': 'admin', 'customJDBCCert': '', 'password': '1234',  
    'vendor': 'mysql'}
```


Transactions

- [start_transaction](#)
- [commit_transaction](#)
- [cancel_transaction](#)

start_transaction

start_transaction(read_only)

Démarrez une nouvelle transaction. Appelle en interne l'API [Démarrer la transaction](#) Lake Formation.

- `read_only` – Valeur booléenne indiquant si cette transaction doit être en lecture seule ou en lecture et en écriture. Les écritures effectuées à l'aide d'un ID de transaction en lecture seule seront rejetées. Les transactions en lecture seule n'ont pas besoin d'être validées.

Retourne l'ID de transaction.

commit_transaction

commit_transaction(transaction_id, wait_for_commit = True)

Tentative de validation de la transaction spécifiée. `commit_transaction` peut être renvoyé avant la fin de la validation de la transaction. Appelle en interne la Lake Formation [commitTransaction](#) API.

- `transaction_id` – (Chaîne) La transaction à valider.
- `wait_for_commit` – (Booléen) Détermine si le `commit_transaction` retourne immédiatement. La valeur par défaut est `True`. Si elle est `false`, `commit_transaction` interroge et attend que la transaction soit validée. Le temps d'attente est limité à 1 minute en utilisant le backoff exponentiel avec un maximum de 6 tentatives de nouvelle tentative.

Renvoie une valeur de type Boolean pour indiquer si la validation est effectuée ou non.

cancel_transaction

cancel_transaction(transaction_id)

Tentative d'annulation de la transaction spécifiée. Retourne une exception `TransactionCommittedException` si la transaction a déjà été validée. Appelle en interne l'[CancelTransaction](#) API Lake Formation.

- `transaction_id` – (Chaîne) La transaction à annuler.

Ecriture

- [getSink](#)
- [write_dynamic_frame_from_options](#)
- [write_from_options](#)
- [write_dynamic_frame_from_catalog](#)
- [write_data_frame_from_catalog](#)
- [write_dynamic_frame_from_jdbc_conf](#)
- [write_from_jdbc_conf](#)

getSink

getSink(connection_type, format = None, transformation_ctx = "", **options)

Obtient un objet `DataSink` qui peut être utilisé pour écrire `DynamicFrames` sur des sources externes. Vérifiez d'abord le format `SparkSQL` pour être sûr d'obtenir le récepteur escompté.

- `connection_type` – type de connexion à utiliser, telle qu'Amazon S3, Amazon Redshift et JDBC. Les valeurs valides incluent `s3mysql`, `postgresqlredshift`, `sqlserver`, `oracle`, `kinesis`, `etkafka`.
- `format` – Format `SparkSQL` à utiliser (facultatif).
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `options` – Ensemble de paires nom-valeur utilisées pour spécifier les options de connexion. Certaines des valeurs possibles sont les suivantes :
 - `user` et `password` : Pour autorisation
 - `url` : Point de terminaison du magasin de données
 - `dbtable` : Nom de la table cible
 - `bulkSize` : Degré de parallélisme pour les opérations d'insertion

Les options que vous pouvez spécifier dépendent du type de connexion. Pour obtenir d'autres conseils et d'autres exemples, veuillez consulter [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#).

Exemple :

```
>>> data_sink = context.getSink("s3")
>>> data_sink.setFormat("json"),
>>> data_sink.writeFrame(myFrame)
```

write_dynamic_frame_from_options

```
write_dynamic_frame_from_options(frame, connection_type,  
connection_options={}, format=None, format_options={}, transformation_ctx =  
"" )
```

Écrit et retourne un `DynamicFrame` à l'aide de la connexion et du format spécifiés.

- `frame` – Objet `DynamicFrame` à écrire.
- `connection_type` – type de connexion, tel qu'Amazon S3, Amazon Redshift et JDBC. Les valeurs valides incluent `s3mysql`, `postgresqlredshift`, `sqlserver`, `oracle`, `kinesis`, `etkafka`.
- `connection_options` – Options de connexion, telles que le chemin et la table de base de données (facultatif). Pour un `connection_type` de `s3`, un chemin Amazon S3 est défini.

```
connection_options = {"path": "s3://aws-glue-target/temp"}
```

Pour les connexions JDBC, plusieurs propriétés doivent être définies. Notez que le nom de base de données doit être inclus dans l'URL. Il peut éventuellement être inclus dans les options de connexion.

Warning

Il n'est pas recommandé de stocker des mots de passe dans votre script. Envisagez de les utiliser `boto3` pour les extraire AWS Secrets Manager du catalogue de données AWS Glue.

```
connection_options = {"url": "jdbc-url/database", "user": "username",  
  "password": passwordVariable, "dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-  
path"}
```

La propriété `dbtable` est le nom de la table JDBC. Pour les magasins de données JDBC qui prennent en charge les schémas dans une base de données, spécifiez `schema.table-name`. Si aucun schéma n'est fourni, c'est le schéma « public » par défaut qui est utilisé.

Pour de plus amples informations, veuillez consulter [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#).

- `format`— Une spécification de format. Utilisée pour une connexion Amazon S3 ou AWS Glue prenant en charge plusieurs formats. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- `format_options` – options de format pour le format spécifié. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).

`write_from_options`

```
write_from_options(frame_or_dfc, connection_type, connection_options={},  
format={}, format_options={}, transformation_ctx = "")
```

Écrit et renvoie un `DynamicFrame` ou `DynamicFrameCollection` qui est créé avec la connexion et les informations de format spécifiées.

- `frame_or_dfc` – Objet `DynamicFrame` ou `DynamicFrameCollection` à écrire.
- `connection_type` – type de connexion, tel qu'Amazon S3, Amazon Redshift et JDBC. Les valeurs valides sont `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver` et `oracle`.
- `connection_options` – Options de connexion, telles que le chemin et la table de base de données (facultatif). Pour un `connection_type` de `s3`, un chemin Amazon S3 est défini.

```
connection_options = {"path": "s3://aws-glue-target/temp"}
```

Pour les connexions JDBC, plusieurs propriétés doivent être définies. Notez que le nom de base de données doit être inclus dans l'URL. Il peut éventuellement être inclus dans les options de connexion.

⚠ Warning

Il n'est pas recommandé de stocker des mots de passe dans votre script. Envisagez de les utiliser boto3 pour les extraire AWS Secrets Manager du catalogue de données AWS Glue.

```
connection_options = {"url": "jdbc-url/database", "user": "username",  
  "password": passwordVariable, "dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

La propriété dbtable est le nom de la table JDBC. Pour les magasins de données JDBC qui prennent en charge les schémas dans une base de données, spécifiez schema.table-name. Si aucun schéma n'est fourni, c'est le schéma « public » par défaut qui est utilisé.

Pour de plus amples informations, veuillez consulter [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#).

- **format**— Une spécification de format. Utilisée pour une connexion Amazon S3 ou AWS Glue prenant en charge plusieurs formats. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- **format_options** – options de format pour le format spécifié. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- **transformation_ctx** – Contexte de transformation à utiliser (facultatif).

`write_dynamic_frame_from_catalog`

```
write_dynamic_frame_from_catalog(frame, database, table_name,  
redshift_tmp_dir, transformation_ctx = "", additional_options = {},  
catalog_id = None)
```

Écrit et renvoie un objet `DynamicFrame` utilisant des informations provenant d'une table et d'une base de données Data Catalog.

- **frame** – Objet `DynamicFrame` à écrire.
- **Database** – base de données Data Catalog contenant la table.

- `table_name` – nom de la table Data Catalog associée à la cible.
- `redshift_tmp_dir` – répertoire Amazon Redshift temporaire à utiliser (facultatif).
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `additional_options` – Ensemble de paires nom-valeur facultatives.
- `catalog_id` – ID du catalogue (ID du compte) Data Catalog auquel vous accédez. Lorsque la valeur est Aucun, l'ID de compte par défaut de l'appelant est utilisé.

`write_data_frame_from_catalog`

```
write_data_frame_from_catalog(frame, database, table_name,  
redshift_tmp_dir, transformation_ctx = "", additional_options = {},  
catalog_id = None)
```

Écrit et renvoie un objet `DataFrame` utilisant des informations provenant d'une table et d'une base de données Data Catalog. Cette méthode prend en charge l'écriture dans les formats de lac de données (Hudi, Iceberg et Delta Lake). Pour plus d'informations, consultez [Utilisation de frameworks de lacs de données avec des tâches AWS Glue ETL](#).

- `frame` – Objet `DataFrame` à écrire.
- `Database` – base de données Data Catalog contenant la table.
- `table_name` – nom de la table Data Catalog qui est associée à la cible.
- `redshift_tmp_dir` – répertoire Amazon Redshift temporaire à utiliser (facultatif).
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `additional_options` – Ensemble de paires nom-valeur facultatives.
- `useSparkDataSink`— Lorsque ce paramètre est défini sur `true`, force AWS Glue à utiliser l'API native de Spark Data Sink pour écrire dans la table. Lorsque vous activez cette option, vous pouvez ajouter toutes les [options de source de données Spark](#) selon `additional_options` vos besoins. AWS Glue transmet ces options directement au Spark Writer.
- `catalog_id` – ID de catalogue (ID de compte) du catalogue de données auquel vous accédez. Si vous ne spécifiez aucune valeur, l'ID de compte par défaut de l'appelant est utilisé.

Limites

Lorsque vous utilisez l'option `useSparkDataSink`, tenez compte des restrictions suivantes :

- L'option [enableUpdateCatalog](#) n'est pas prise en charge lorsque vous utilisez l'option `useSparkDataSink`.

Exemple : Écriture dans une table Hudi à l'aide de l'enregistreur de source de données Spark

```
hudi_options = {
    'useSparkDataSink': True,
    'hoodie.table.name': <table_name>,
    'hoodie.datasource.write.storage.type': 'COPY_ON_WRITE',
    'hoodie.datasource.write.recordkey.field': 'product_id',
    'hoodie.datasource.write.table.name': <table_name>,
    'hoodie.datasource.write.operation': 'upsert',
    'hoodie.datasource.write.precombine.field': 'updated_at',
    'hoodie.datasource.write.hive_style_partitioning': 'true',
    'hoodie.upsert.shuffle.parallelism': 2,
    'hoodie.insert.shuffle.parallelism': 2,
    'hoodie.datasource.hive_sync.enable': 'true',
    'hoodie.datasource.hive_sync.database': <database_name>,
    'hoodie.datasource.hive_sync.table': <table_name>,
    'hoodie.datasource.hive_sync.use_jdbc': 'false',
    'hoodie.datasource.hive_sync.mode': 'hms'}

glueContext.write_data_frame.from_catalog(
    frame = <df_product_inserts>,
    database = <database_name>,
    table_name = <table_name>,
    additional_options = hudi_options
)
```

`write_dynamic_frame_from_jdbc_conf`

`write_dynamic_frame_from_jdbc_conf(frame, catalog_connection, connection_options={}, redshift_tmp_dir = "", transformation_ctx = "", catalog_id = None)`

Écrit et retourne un `DynamicFrame` à l'aide des informations de connexion JDBC spécifiées.

- `frame` – Objet `DynamicFrame` à écrire.
- `catalog_connection` – Connexion de catalogue à utiliser.

- `connection_options` – Options de connexion, telles que le chemin et la table de base de données (facultatif). Pour plus d'informations, consultez [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#).
- `redshift_tmp_dir` – répertoire Amazon Redshift temporaire à utiliser (facultatif).
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `catalog_id` – ID du catalogue (ID du compte) Data Catalog auquel vous accédez. Lorsque la valeur est Aucun, l'ID de compte par défaut de l'appelant est utilisé.

`write_from_jdbc_conf`

```
write_from_jdbc_conf(frame_or_dfc, catalog_connection,  
connection_options={}, redshift_tmp_dir = "", transformation_ctx = "",  
catalog_id = None)
```

Écrit et retourne un objet `DynamicFrame` ou `DynamicFrameCollection` à l'aide des informations de connexion JDBC spécifiées.

- `frame_or_dfc` – Objet `DynamicFrame` ou `DynamicFrameCollection` à écrire.
- `catalog_connection` – Connexion de catalogue à utiliser.
- `connection_options` – Options de connexion, telles que le chemin et la table de base de données (facultatif). Pour plus d'informations, consultez [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#).
- `redshift_tmp_dir` – répertoire Amazon Redshift temporaire à utiliser (facultatif).
- `transformation_ctx` – Contexte de transformation à utiliser (facultatif).
- `catalog_id` – ID du catalogue (ID du compte) Data Catalog auquel vous accédez. Lorsque la valeur est Aucun, l'ID de compte par défaut de l'appelant est utilisé.

AWS Glue PySpark transforme la référence

AWS Glue fournit les transformations intégrées suivantes que vous pouvez utiliser dans les opérations PySpark ETL. Vos données passent d'une transformation à l'autre dans une structure de données appelée `DynamicFrame`, qui est une extension d'un SQL Apache `SparkDataFrame`. Le `DynamicFrame` contient vos données, et vous référencez son schéma pour traiter vos données.

La plupart de ces transformations existent également en tant que méthodes de la classe `DynamicFrame`. Pour plus d'informations, consultez la section [DynamicFrame transformations](#).

- [GlueTransform classe de base](#)
- [ApplyMapping classe](#)
- [DropFields classe](#)
- [DropNullFields classe](#)
- [ErrorsAsDynamicFrame classe](#)
- [EvaluateDataQuality classe](#)
- [FillMissingValues classe](#)
- [Classe Filter](#)
- [FindIncrementalMatches classe](#)
- [FindMatches classe](#)
- [FlatMap classe](#)
- [Classe Join](#)
- [Classe Map](#)
- [MapToCollection classe](#)
- [mergeDynamicFrame](#)
- [Classe Relationalize](#)
- [RenameField classe](#)
- [ResolveChoice classe](#)
- [SelectFields classe](#)
- [SelectFromCollection classe](#)
- [Classe Simplify_DDB_JSON](#)
- [Classe Spigot](#)
- [SplitFields classe](#)
- [SplitRows classe](#)
- [Classe Unbox](#)
- [UnnestFrame classe](#)

GlueTransform classe de base

Classe de base dont toutes les classes `aws glue.transforms` héritent.

Les classes définissent toutes une méthode `__call__`. Elles remplacent les méthodes de la classe `GlueTransform` répertoriées dans les sections suivantes ou sont appelées en utilisant le nom de classe par défaut.

Méthodes

- [`apply\(cls, \*args, \*\*kwargs\)`](#)
- [`name\(cls\)`](#)
- [`describeArgs\(cls\)`](#)
- [`describeReturn\(cls\)`](#)
- [`describeTransform\(cls\)`](#)
- [`describeErrors\(cls\)`](#)
- [`describe\(cls\)`](#)

`apply(cls, *args, **kwargs)`

Applique la transformation en appelant la classe de transformation et renvoie le résultat.

- `cls` – Objet de classe `self`.

`name(cls)`

Retourne le nom de la classe de transformation dérivée.

- `cls` – Objet de classe `self`.

`describeArgs(cls)`

- `cls` – Objet de classe `self`.

Renvoie une liste de dictionnaires, chacun correspondant à un argument nommé, dans le format suivant :

```
[
  {
    "name": "(name of argument)",
    "type": "(type of argument)",
```

```
"description": "(description of argument)",
"optional": "(Boolean, True if the argument is optional)",
"defaultvalue": "(Default value string, or None)(String; the default value, or
None)"
},
...
]
```

Lève une exception `NotImplementedError` en cas d'appel dans une transformation dérivée où elle n'est pas implémentée.

`describeReturn(cls)`

- `cls` – Objet de classe `self`.

Renvoie un dictionnaire avec les informations sur le type de retour, dans le format suivant :

```
{
  "type": "(return type)",
  "description": "(description of output)"
}
```

Lève une exception `NotImplementedError` en cas d'appel dans une transformation dérivée où elle n'est pas implémentée.

`describeTransform(cls)`

Renvoie une chaîne décrivant la transformation.

- `cls` – Objet de classe `self`.

Lève une exception `NotImplementedError` en cas d'appel dans une transformation dérivée où elle n'est pas implémentée.

`describeErrors(cls)`

- `cls` – Objet de classe `self`.

Renvoie une liste de dictionnaires, chacun décrivant une exception éventuelle lancée par cette transformation, dans le format suivant :

```
[
  {
    "type": "(type of error)",
    "description": "(description of error)"
  },
  ...
]
```

describe(cls)

- cls – Objet de classe self.

Renvoie un objet dans le format suivant :

```
{
  "transform" : {
    "name" : cls.name( ),
    "args" : cls.describeArgs( ),
    "returns" : cls.describeReturn( ),
    "raises" : cls.describeErrors( ),
    "location" : "internal"
  }
}
```

ApplyMapping classe

Applique un mappage dans un DynamicFrame.

exemple

Nous vous recommandons d'utiliser le [DynamicFrame.apply_mapping\(\)](#) méthode pour appliquer un mappage dans un DynamicFrame. Vous trouverez un exemple de code, consultez [Exemple : Utilisez apply_mapping afin de renommer des champs ainsi que de modifier ses types](#) .

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)

- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [Describe](#)

`__call__(frame, mappings, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)`

Applique un mappage déclaratif à un `DynamicFrame` spécifié.

- `frame` – le `DynamicFrame` appliquer le mappage (obligatoire).
- `mappings`— Une liste de tuples de mappage (obligatoire). Chacun étant composé comme suit : (colonne source, type source, colonne cible, type cible).

Si la colonne source comporte un point « . » dans le nom, vous devez cocher une case arrière « ` » autour de lui. Par exemple, pour mapper `this.old.name` (chaîne) à `thisNewName`, vous devez utiliser le tuple suivant :

```
("`this.old.name`", "string", "thisNewName", "string")
```

- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.

Renvoie uniquement les champs du `DynamicFrame` spécifié dans les tuples de « mappage ».

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

describeArgs(cls)

Hérité de GlueTransform [describeArgs](#).

describeReturn(cls)

Hérité de GlueTransform [describeReturn](#).

describeTransform(cls)

Hérité de GlueTransform [describeTransform](#).

describeErrors(cls)

Hérité de GlueTransform [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

DropFields classe

Déplace des champs au sein d'un DynamicFrame.

exemple

Nous vous recommandons d'utiliser la [DynamicFrame.drop_fields\(\)](#) méthode pour supprimer des champs d'un DynamicFrame. Vous trouverez un exemple de code, consultez [Exemple : utilisez supprimer les champs pour supprimer les champs d'un DynamicFrame](#).

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [Describe](#)

```
__call__(frame, paths, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)
```

Déplace des nœuds au sein d'un `DynamicFrame`.

- `frame` – Le `DynamicFrame` dans lequel supprimer les nœuds (obligatoire).
- `paths` – Liste des chemins complets vers les nœuds à déplacer (obligatoire).
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.

Renvoie un nouveau `DynamicFrame` sans les champs spécifiés.

```
apply(cls, *args, **kwargs)
```

Hérité de `GlueTransform` [s'appliquent](#).

```
name(cls)
```

Hérité de `GlueTransform` [name](#).

```
describeArgs(cls)
```

Hérité de `GlueTransform` [describeArgs](#).

```
describeReturn(cls)
```

Hérité de `GlueTransform` [describeReturn](#).

```
describeTransform(cls)
```

Hérité de `GlueTransform` [describeTransform](#).

```
describeErrors(cls)
```

Hérité de `GlueTransform` [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

DropNullFields classe

Rejette tous les champs null dans un DynamicFrame dont le type est NullType. Il s'agit des champs comportant des valeurs manquantes ou nulles dans chaque enregistrement de l'ensemble de données DynamicFrame.

exemple

Cet exemple utilise DropNullFields pour créer un nouveau DynamicFrame où les champs de type NullType ont été abandonnés. Afin de démontrer DropNullFields, nous ajoutons une nouvelle colonne nommée empty_column de type null pour le jeu de données persons déjà chargé.

Note

Pour accéder au jeu de données utilisé dans cet exemple, voir [Exemple de code : Données de jonction et de mise en relation](#) et suivez les instructions de la section [Étape 1 : analyser les données dans le compartiment Amazon S3](#).

```
# Example: Use DropNullFields to create a new DynamicFrame without NullType fields

from pyspark.context import SparkContext
from awsglue.context import GlueContext
from pyspark.sql.functions import lit
from pyspark.sql.types import NullType
from awsglue.dynamicframe import DynamicFrame
from awsglue.transforms import DropNullFields

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Create DynamicFrame
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="persons_json"
)
```



```
print("Schema for the persons DynamicFrame:")
persons.printSchema()

# Add new column "empty_column" with NullType
persons_with_nulls = persons.toDF().withColumn("empty_column",
    lit(None).cast(NullType()))
persons_with_nulls_dyf = DynamicFrame.fromDF(persons_with_nulls, glueContext,
    "persons_with_nulls")
print("Schema for the persons_with_nulls_dyf DynamicFrame:")
persons_with_nulls_dyf.printSchema()

# Remove the NullType field
persons_no_nulls = DropNullFields.apply(persons_with_nulls_dyf)
print("Schema for the persons_no_nulls DynamicFrame:")
persons_no_nulls.printSchema()
```

Sortie

```
Schema for the persons DynamicFrame:
root
|-- family_name: string
|-- name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- other_names: array
|   |-- element: struct
|   |   |-- lang: string
|   |   |-- note: string
|   |   |-- name: string
|-- sort_name: string
|-- images: array
|   |-- element: struct
|   |   |-- url: string
|-- given_name: string
|-- birth_date: string
```

```
|-- id: string
|-- contact_details: array
|   |-- element: struct
|   |   |-- type: string
|   |   |-- value: string
|-- death_date: string
```

Schema for the persons_with_nulls_dyf DynamicFrame:

```
root
|-- family_name: string
|-- name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- other_names: array
|   |-- element: struct
|   |   |-- lang: string
|   |   |-- note: string
|   |   |-- name: string
|-- sort_name: string
|-- images: array
|   |-- element: struct
|   |   |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|   |-- element: struct
|   |   |-- type: string
|   |   |-- value: string
|-- death_date: string
|-- empty_column: null
```

```
null_fields ['empty_column']
```

Schema for the persons_no_nulls DynamicFrame:

```
root
|-- family_name: string
```

```
|-- name: string
|-- links: array
|   |-- element: struct
|   |   |-- note: string
|   |   |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|   |-- element: struct
|   |   |-- scheme: string
|   |   |-- identifier: string
|-- other_names: array
|   |-- element: struct
|   |   |-- lang: string
|   |   |-- note: string
|   |   |-- name: string
|-- sort_name: string
|-- images: array
|   |-- element: struct
|   |   |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|   |-- element: struct
|   |   |-- type: string
|   |   |-- value: string
|-- death_date: string
```

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [Describe](#)

```
__call__(frame, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)
```

Rejette tous les champs null dans un `DynamicFrame` dont le type est `NullType`. Il s'agit des champs comportant des valeurs manquantes ou nulles dans chaque enregistrement de l'ensemble de données `DynamicFrame`.

- `frame` – `DynamicFrame` dans lequel déposer les champs nuls (obligatoire).
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.

Renvoie un nouveau `DynamicFrame` sans champ null.

```
apply(cls, *args, **kwargs)
```

- `cls` – `cls`

```
name(cls)
```

- `cls` – `cls`

```
describeArgs(cls)
```

- `cls` – `cls`

```
describeReturn(cls)
```

- `cls` – `cls`

```
describeTransform(cls)
```

- `cls` – `cls`

describeErrors(cls)

- cls – cls

describe(cls)

- cls – cls

ErrorsAsDynamicFrame classe

Renvoie un `DynamicFrame` qui contient des enregistrements imbriqués pour les erreurs survenues lors de la source `DynamicFrame` a été créé.

exemple

Nous vous recommandons d'utiliser la [DynamicFrame.errorsAsDynamicFrame\(\)](#) méthode pour récupérer et afficher les enregistrements d'erreurs. Vous trouverez un exemple de code, consultez [Exemple : utilisez errorsAsDynamic Frame pour afficher les enregistrements d'erreurs](#).

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [Describe](#)

__call__(frame)

Renvoie un `DynamicFrame` qui contient des enregistrements d'erreurs liés au `DynamicFrame` source.

- frame – `DynamicFrame` source (obligatoire).

`apply(cls, *args, **kwargs)`

- `cls – cls`

`name(cls)`

- `cls – cls`

`describeArgs(cls)`

- `cls – cls`

`describeReturn(cls)`

- `cls – cls`

`describeTransform(cls)`

- `cls – cls`

`describeErrors(cls)`

- `cls – cls`

`describe(cls)`

- `cls – cls`

`EvaluateDataQuality` classe

Évalue un jeu de règles de qualité des données par rapport à un `DynamicFrame` et renvoie un nouveau `DynamicFrame` avec les résultats de l'évaluation.

exemple

L'exemple de code suivant montre comment évaluer la qualité des données pour un `DynamicFrame`, puis afficher les résultats relatifs à la qualité des données.

```
from awsglue.transforms import *
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsgluedq.transforms import EvaluateDataQuality

#Create Glue context
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Define DynamicFrame
legislatorsAreas = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="areas_json")

# Create data quality ruleset
ruleset = """Rules = [ColumnExists "id", IsComplete "id"]"""

# Evaluate data quality
dqResults = EvaluateDataQuality.apply(
    frame=legislatorsAreas,
    ruleset=ruleset,
    publishing_options={
        "dataQualityEvaluationContext": "legislatorsAreas",
        "enableDataQualityCloudWatchMetrics": True,
        "enableDataQualityResultsPublishing": True,
        "resultsS3Prefix": "amzn-s3-demo-bucket1",
    },
)

# Inspect data quality results
dqResults.printSchema()
dqResults.toDF().show()
```

Sortie

```
root
|-- Rule: string
|-- Outcome: string
|-- FailureReason: string
|-- EvaluatedMetrics: map
|   |-- keyType: string
|   |-- valueType: double
```

```

+-----+-----+-----+-----+
|Rule           |Outcome|FailureReason|EvaluatedMetrics|
+-----+-----+-----+-----+
|ColumnExists "id"      |Passed |null         |{}              |
|IsComplete "id"       |Passed |null         |{Column.first_name.Completeness -> 1.0}|
+-----+-----+-----+-----+

```

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

`__call__` (trame, jeu de règles, options de publication = {})

- `frame` – Le `DynamicFrame` dont vous souhaitez évaluer la qualité des données.
- `ruleset` – Jeu de règles DQDL (Data Quality Definition Language) au format de chaîne. Pour en savoir plus sur DQDL, consultez le guide [Référence DQDL \(Data Quality Definition Language\)](#).
- `publishing_options` – Dictionnaire qui spécifie les options de publication suivantes des résultats et des métriques d'une évaluation :
 - `dataQualityEvaluationContext`— Chaîne qui indique l'espace de noms sous lequel AWS Glue doit publier Amazon CloudWatch les métriques et les résultats de qualité des données. Les statistiques agrégées apparaissent dans CloudWatch, tandis que les résultats complets apparaissent dans l'interface de AWS Glue Studio.
 - Obligatoire : non
 - Valeur par défaut : `default_context`
 - `enableDataQualityCloudWatchMetrics`— Spécifie si les résultats de l'évaluation de la qualité des données doivent être publiés sur CloudWatch. Vous spécifiez un espace de noms pour les métriques à l'aide de l'option `dataQualityEvaluationContext`.

- Obligatoire : non
- Valeur par défaut : False
- `enableDataQualityResultsPublishing` – Spécifie si les résultats relatifs à la qualité des données doivent être visibles dans l'onglet Data Quality (Qualité des données) de l'interface AWS Glue Studio.
 - Obligatoire : non
 - Valeur par défaut : True
- `resultsS3Prefix`— Spécifie l'emplacement Amazon S3 où AWS Glue peut écrire les résultats de l'évaluation de la qualité des données.
 - Obligatoire : non
 - Valeur par défaut : "" (chaîne vide)

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

`describe(cls)`

Hérité de `GlueTransform` [describe](#).

FillMissingValues classe

La classe `FillMissingValues` localise les valeurs nulles et les chaînes vides dans un élément `DynamicFrame` spécifié et utilise des méthodes de machine learning, telles que la régression linéaire et la forêt aléatoire, pour prédire les valeurs manquantes. La tâche ETL utilise les valeurs de l'ensemble de données d'entrée pour entraîner le modèle de machine learning, qui prédit ensuite quelles devraient être les valeurs manquantes.

Tip

Si vous utilisez des jeux de données incrémentiels, chacun d'entre eux est utilisé comme données d'entraînement pour le modèle de machine learning, de sorte que les résultats peuvent ne pas être aussi précis.

Pour importer :

```
from awsglueml.transforms import FillMissingValues
```

Méthodes

- [Appliquer](#)

```
apply(frame, missing_values_column, output_column="", transformation_ctx="", info="",  
stageThreshold = 0, totalThreshold = 0)
```

Remplit les valeurs manquantes d'un cadre dynamique dans une colonne spécifiée et renvoie un nouveau cadre avec des estimations dans une nouvelle colonne. Pour les lignes sans valeurs manquantes, la valeur de la colonne spécifiée est dupliquée dans la nouvelle colonne.

- `frame` – `DynamicFrame` dans lequel renseigner les valeurs manquantes. Obligatoire.
- `missing_values_column` – colonne contenant les valeurs manquantes (valeurs `null` et chaînes vides). Obligatoire.
- `output_column` – nom de la nouvelle colonne qui contiendra les valeurs estimées pour toutes les lignes dont la valeur était manquante. Facultatif ; la valeur par défaut est le nom de `missing_values_column` avec le suffixe `"_filled"`.
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).

- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – Nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée (facultatif ; la valeur par défaut est zéro).
- `totalThreshold` – Nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté (facultatif ; la valeur par défaut est zéro).

Renvoie un nouveau `DynamicFrame` avec une colonne supplémentaire qui contient des estimations pour les lignes avec des valeurs manquantes et la valeur actuelle pour les autres lignes.

Classe Filter

Construit un nouvel `DynamicFrame` contenant des enregistrements en entrée `DynamicFrame` qui satisfont à une fonction de prédicat spécifié

exemple

Nous vous recommandons d'utiliser la [DynamicFrame.filter\(\)](#) méthode pour supprimer des champs d'un `DynamicFrame`. Vous trouverez un exemple de code, consultez [Exemple : Utiliser un filtre pour obtenir une sélection de champs filtrée](#).

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

```
__call__(frame, f, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0))
```

Retourne un nouvel objet `DynamicFrame` construit en sélectionnant les enregistrements en entrée `DynamicFrame` qui satisfont à une fonction de prédicat spécifiée.

- `frame` – Objet `DynamicFrame` source auquel appliquer la fonction de filtre spécifiée (requis).

- `f` – fonction de prédicat à appliquer à chaque `DynamicRecord` de l'objet `DynamicFrame`. La fonction doit accepter un `DynamicRecord` comme argument et renvoyer la valeur Vraie si le `DynamicRecord` répond aux critères du filtre, ou la valeur Faux dans le cas contraire (obligatoire).

Un `DynamicRecord` représente un enregistrement logique dans un `DynamicFrame`. Il est comparable à une ligne dans un `Spark DataFrame`, à la différence qu'il est auto-descriptif et peut être utilisé pour les données qui ne sont pas conformes à un schéma fixe.

- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

`describe(cls)`

Hérité de `GlueTransform` [describe](#).

`FindIncrementalMatches` classe

Identifie les enregistrements correspondants dans les `DynamicFrame` existants et incrémentiels, et crée un `DynamicFrame` avec un identifiant unique affecté à chaque groupe d'enregistrements correspondants.

Pour importer :

```
from awsglueml.transforms import FindIncrementalMatches
```

Méthodes

- [Appliquer](#)

`appliquer (ExistingFrame, IncrementalFrame, TransformId, transformation_ctx = « », info = « », StageThreshold = 0, TotalThreshold = 0, EnforcedMatches = aucun, Scores = 0)`
`computeMatchConfidence`

Identifie les enregistrements correspondants dans l'entrée `DynamicFrame`, et crée un `DynamicFrame` avec un identifiant unique affecté à chaque groupe d'enregistrements correspondants.

- `existingFrame`— L'existant et le préapparié `DynamicFrame` pour appliquer la `FindIncrementalMatches` transformation. Obligatoire.
- `incrementalFrame`— L'incrémentiel `DynamicFrame` à appliquer à la `FindIncrementalMatches` transformation pour qu'elle corresponde `existingFrame` à. Obligatoire.
- `transformId`— L'identifiant unique associé à la `FindIncrementalMatches` transformation à appliquer aux enregistrements du `DynamicFrames`. Obligatoire.
- `transformation_ctx` – chaîne unique utilisée pour identifier les informations sur l'état/statistiques. Facultatif.
- `info` – chaîne à associer à des erreurs dans la transformation. Facultatif.
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée. Facultatif. La valeur par défaut est zéro.

- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté. Facultatif. La valeur par défaut est zéro.
- `enforcedMatches` – `DynamicFrame` utilisé pour appliquer les correspondances. Facultatif. La valeur par défaut est Aucun.
- `computeMatchConfidenceScores` – Valeur booléenne indiquant s'il faut calculer un score de confiance pour chaque groupe de registres correspondant. Facultatif. La valeur par défaut est false.

Renvoie un nouveau `DynamicFrame` avec un identifiant unique affecté à chaque groupe d'enregistrements correspondants.

FindMatches classe

Identifie les enregistrements correspondants dans l'entrée `DynamicFrame`, et crée un `DynamicFrame` avec un identifiant unique affecté à chaque groupe d'enregistrements correspondants.

Pour importer :

```
from awsglueml.transforms import FindMatches
```

Méthodes

- [Appliquer](#)

`appliquer (frame, TransformId, transformation_ctx = « », info = « », StageThreshold = 0, TotalThreshold = 0, EnforcedMatches = aucun, Scores = 0) computeMatchConfidence`

Identifie les enregistrements correspondants dans l'entrée `DynamicFrame`, et crée un `DynamicFrame` avec un identifiant unique affecté à chaque groupe d'enregistrements correspondants.

- `frame`— Le `DynamicFrame` pour appliquer la `FindMatches` transformation. Obligatoire.
- `transformId`— L'identifiant unique associé à la `FindMatches` transformation à appliquer aux enregistrements du `DynamicFrame`. Obligatoire.
- `transformation_ctx` – chaîne unique utilisée pour identifier les informations sur l'état/statistiques. Facultatif.
- `info` – chaîne à associer à des erreurs dans la transformation. Facultatif.

- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée. Facultatif. La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté. Facultatif. La valeur par défaut est zéro.
- `enforcedMatches` – `DynamicFrame` utilisé pour appliquer les correspondances. Facultatif. La valeur par défaut est Aucun.
- `computeMatchConfidenceScores` – Valeur booléenne indiquant s'il faut calculer un score de confiance pour chaque groupe de registres correspondant. Facultatif. La valeur par défaut est `false`.

Renvoie un nouveau `DynamicFrame` avec un identifiant unique affecté à chaque groupe d'enregistrements correspondants.

FlatMap classe

Applique une transformation à chaque `DynamicFrame` d'une collection. Les résultats ne sont pas aplatis en un seul `DynamicFrame`, mais conservés sous forme de collection.

Exemples pour FlatMap

L'exemple d'extrait suivant montre comment utiliser la transformation `ResolveChoice` sur une collection de cadres dynamiques lorsqu'elle est appliquée à un `FlatMap`. Les données utilisées pour l'entrée se trouvent dans le JSON situé à l'adresse Amazon S3 de l'espace réservé `s3://bucket/path-for-data/sample.json` et contiennent les données suivantes.

Exemple de données JSON

```
[{
  "firstname": "Arnav",
  "lastname": "Desai",
  "address": {
    "street": "6 Anyroad Avenue",
    "city": "London",
    "state": "England",
    "country": "UK"
  },
  "phone": 17235550101,
  "affiliations": [
    "General Anonymous Example Products",
    "Example Independent Research",
    "Government Department of Examples"
  ]
}]
```

```
]
},
{
  "firstname": "Mary",
  "lastname": "Major",
  "address": {
    "street": "7821 Spot Place",
    "city": "Centerville",
    "state": "OK",
    "country": "US"
  },
  "phone": 19185550023,
  "affiliations": [
    "Example Dot Com",
    "Example Independent Research",
    "Example.io"
  ]
},
{
  "firstname": "Paulo",
  "lastname": "Santos",
  "address": {
    "street": "123 Maple Street",
    "city": "London",
    "state": "Ontario",
    "country": "CA"
  },
  "phone": 12175550181,
  "affiliations": [
    "General Anonymous Example Products",
    "Example Dot Com"
  ]
}]
}}
```

Exemple Appliquer ResolveChoice à une sortie DynamicFrameCollection et afficher.

```
#Read DynamicFrame
datasource = glueContext.create_dynamic_frame_from_options("s3", connection_options =
  {"paths":["s3://bucket/path/to/file/mysamplejson.json"]}, format="json")
datasource.printSchema()
datasource.show()

## Split to create a DynamicFrameCollection
```



```
split_frame=datasource.split_fields(["firstname","lastname","address"],"personal_info","business_info")
split_frame.keys()
print("---")

## Use FlatMap to run ResolveChoice
kwargs = {"choice": "cast:string"}
flat = FlatMap.apply(split_frame, ResolveChoice, frame_name="frame",
    transformation_ctx='tcx', **kwargs)
flat.keys()

##Select one of the DynamicFrames
personal_info = flat.select("personal_info")
personal_info.printSchema()
personal_info.show()
print("---")

business_info = flat.select("business_info")
business_info.printSchema()
business_info.show()
```

Important

Lorsque vous appelez `FlatMap.apply`, le paramètre `frame_name` doit être `"frame"`. Aucune autre valeur n'est actuellement acceptée.

Exemple de sortie

```
root
|-- firstname: string
|-- lastname: string
|-- address: struct
|   |-- street: string
|   |-- city: string
|   |-- state: string
|   |-- country: string
|-- phone: long
|-- affiliations: array
|   |-- element: string
---
{
  "firstname": "Mary",
```

```

    "lastname": "Major",
    "address": {
        "street": "7821 Spot Place",
        "city": "Centerville",
        "state": "OK",
        "country": "US"
    },
    "phone": 19185550023,
    "affiliations": [
        "Example Dot Com",
        "Example Independent Research",
        "Example.io"
    ]
}

{
    "firstname": "Paulo",
    "lastname": "Santos",
    "address": {
        "street": "123 Maple Street",
        "city": "London",
        "state": "Ontario",
        "country": "CA"
    },
    "phone": 12175550181,
    "affiliations": [
        "General Anonymous Example Products",
        "Example Dot Com"
    ]
}

---
root
|-- firstname: string
|-- lastname: string
|-- address: struct
|   |-- street: string
|   |-- city: string
|   |-- state: string
|   |-- country: string

{
    "firstname": "Mary",
    "lastname": "Major",
    "address": {

```

```

        "street": "7821 Spot Place",
        "city": "Centerville",
        "state": "OK",
        "country": "US"
    }
}

{
    "firstname": "Paulo",
    "lastname": "Santos",
    "address": {
        "street": "123 Maple Street",
        "city": "London",
        "state": "Ontario",
        "country": "CA"
    }
}
---
root
|-- phone: long
|-- affiliations: array
|   |-- element: string

{
    "phone": 19185550023,
    "affiliations": [
        "Example Dot Com",
        "Example Independent Research",
        "Example.io"
    ]
}

{
    "phone": 12175550181,
    "affiliations": [
        "General Anonymous Example Products",
        "Example Dot Com"
    ]
}

```

Méthodes

- [call](#)

- [Appliquer](#)
- [Nom](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [Describe](#)

`__call__ (dfc, nom_cadre BaseTransform, transformation_ctx = « », **base_kwargs)`

Applique une transformation à chaque DynamicFrame d'une collection et aplatit les résultats.

- `dfc` – DynamicFrameCollection sur lequel effectuer un flatmap (obligatoire).
- `BaseTransform` – Transformation dérivée de `GlueTransform` à appliquer à chaque membre de la collection (obligatoire).
- `frame_name` – Nom de l'argument auquel transmettre les éléments de la collection (obligatoire).
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `base_kwargs` – Arguments à transmettre à la transformation de base (obligatoire).

Retourne un nouvel objet `DynamicFrameCollection` en appliquant la transformation à chaque `DynamicFrame` de l'objet `DynamicFrameCollection` source.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

describeTransform(cls)

Hérité de GlueTransform [describeTransform](#).

describeErrors(cls)

Hérité de GlueTransform [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

Classe Join

Effectue une jointure d'égalité sur deux DynamicFrames.

exemple

Nous vous recommandons d'utiliser la [DynamicFrame.join\(\)](#) méthode pour joindre DynamicFrames. Vous trouverez un exemple de code, consultez [Exemple : Utiliser la jointure pour combinerDynamicFrames](#).

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [Describe](#)

`__call__(frame1, frame2, keys1, keys2, transformation_ctx = "")`

Effectue une jointure d'égalité sur deux DynamicFrames.

- frame1 – Premier DynamicFrame à joindre (obligatoire).
- frame2 – Second DynamicFrame à joindre (obligatoire).
- keys1 – Clés à joindre pour la première trame (obligatoire).

- `keys2` – Clés à joindre pour la seconde trame (obligatoire).
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).

Renvoie un nouveau `DynamicFrame` qui est créé en joignant les deux `DynamicFrames`.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

`describe(cls)`

Hérité de `GlueTransform` [describe](#).

Classe `Map`

Crée un nouvel objet `DynamicFrame` en appliquant une fonction à tous les objets `DynamicFrame` en entrée.

exemple

Nous vous recommandons d'utiliser le [DynamicFrame.map\(\)](#) méthode pour appliquer une fonction à tous les enregistrements dans `DynamicFrame`. Vous trouverez un exemple de code,

consultez [Exemple : utilisez la carte pour appliquer une fonction à chaque enregistrement dans un DynamicFrame](#).

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [Describe](#)

```
__call__(frame, f, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)
```

Renvoie un nouvel objet `DynamicFrame` qui résulte de l'application de la fonction spécifiée à tous les `DynamicRecords` de l'objet `DynamicFrame` d'origine.

- `frame` – Objet `DynamicFrame` d'origine auquel appliquer la fonction de mappage (obligatoire).
- `f` – fonction à tous les `DynamicRecords` de l'objet `DynamicFrame`. La fonction doit accepter un `DynamicRecord` comme argument et renvoyer un nouvel objet `DynamicRecord` produit par le mappage (obligatoire).

Un `DynamicRecord` représente un enregistrement logique dans un `DynamicFrame`. Il est comparable à une ligne dans un `DataFrame` Apache Spark, à la différence qu'il est auto-descriptif et peut être utilisé pour les données qui ne sont pas conformes à un schéma fixe.

- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.

Renvoie un nouvel objet `DynamicFrame` qui résulte de l'application de la fonction spécifiée à tous les `DynamicRecords` de l'objet `DynamicFrame` d'origine.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

`describe(cls)`

Hérité de `GlueTransform` [describe](#).

`MapToCollection` classe

Applique une transformation à chaque `DynamicFrame` de l'objet `DynamicFrameCollection` spécifié.

Méthodes

- [__call__](#)
- [Appliquer](#)
- [Nom](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)

- [describeErrors](#)
- [Describe](#)

`__call__ (dfc, nom_cadre BaseTransform, transformation_ctx = « », **base_kwargs)`

Applique une fonction de transformation à chaque `DynamicFrame` de l'objet `DynamicFrameCollection` spécifié.

- `dfc` – L'objet `DynamicFrameCollection` sur lequel appliquer la fonction de transformation (requis).
- `callable` – Une fonction de transformation callable à appliquer à chaque membre de la collection (obligatoire).
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).

Retourne un nouvel objet `DynamicFrameCollection` en appliquant la transformation à chaque `DynamicFrame` de l'objet `DynamicFrameCollection` source.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#)

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

Classe Relationalize

Aplatit le schéma imbriqué dans une image DynamicFrame et fait pivoter les colonnes de tableaux de l'image aplatie.

exemple

Nous vous recommandons d'utiliser la méthode [DynamicFrame.relationalize\(\)](#) pour mettre en relation une image DynamicFrame. Vous trouverez un exemple de code, consultez [Exemple : utiliser la méthode relationalize pour aplatir un schéma imbriqué dans une image DynamicFrame](#).

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

```
__call__(frame, staging_path=None, name='roottable', options=None, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)
```

Met en relation un DynamicFrame et produit une liste des trames qui sont générées en supprimant l'imbrication des colonnes imbriquées et en faisant pivoter des colonnes de tableaux. Vous pouvez joindre une colonne de tableau ayant été pivotée à la table racine à l'aide de la clé de jointure générée au cours de la phase de désimbrication.

- `frame` – DynamicFrame à mettre en relation (obligatoire).
- `staging_path` – Chemin d'accès auquel la méthode peut stocker des partitions des tables dynamiques au format CSV format (facultatif). Les tables dynamiques sont lues à partir de ce chemin.

- `name` – Nom de la table racine (facultatif).
- `options` – Dictionnaire des paramètres facultatifs. Non utilisé actuellement.
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

`describe(cls)`

Hérité de `GlueTransform` [describe](#).

`RenameField` classe

Renomme un nœud dans un `DynamicFrame`.

exemple

Nous vous recommandons d'utiliser la méthode [DynamicFrame.rename_field\(\)](#) pour renommer un champ dans une image DynamicFrame. Vous trouverez un exemple de code, consultez [Exemple : utiliser la méthode rename_field pour renommer des champs dans une image DynamicFrame](#).

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

```
__call__(frame, old_name, new_name, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)
```

Renomme un nœud dans un DynamicFrame.

- `frame` – DynamicFrame dans lequel renommer un nœud (obligatoire).
- `old_name` – Chemin d'accès complet au nœud à renommer (obligatoire).

Si l'ancien nom comporte des points, cela ne RenameField fonctionnera pas à moins que vous ne le contourniez (```). Par exemple, pour remplacer `this.old.name` par `thisNewName`, vous devez appeler RenameField comme suit :

```
newDyF = RenameField(oldDyF, "`this.old.name`", "thisNewName")
```

- `new_name` – Nouveau nom, y compris le chemin d'accès complet (obligatoire).
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).

- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

`describe(cls)`

Hérité de `GlueTransform` [describe](#).

`ResolveChoice` classe

Résout un type de choix au sein d'un `DynamicFrame`.

exemple

Nous vous recommandons d'utiliser la méthode [DynamicFrame.resolveChoice\(\)](#) pour gérer les champs contenant plusieurs types dans une image `DynamicFrame`. Vous trouverez un exemple

de code, consultez [Exemple : utiliser la méthode resolveChoice pour gérer une colonne contenant plusieurs types](#).

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

```
__call__(frame, specs = None, choice = "", transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)
```

Fournit des informations pour résoudre les types ambigus au sein d'un `DynamicFrame`. Renvoie l'image `DynamicFrame` obtenue.

- `frame` – `DynamicFrame` dans lequel résoudre le type de choix (obligatoire).
- `specs` – Liste d'ambiguïtés spécifiques à résoudre, apparaissant sous forme de tuple: (`path`, `action`). La valeur `path` identifie un élément ambigu spécifique, et la valeur `action` identifie la résolution correspondante.

Vous ne pouvez utiliser qu'un seul des paramètres `spec` et `choice`. Si le paramètre `spec` n'est pas `None`, alors le paramètre `choice` doit être une chaîne vide. Inversement, si le paramètre `choice` n'est pas une chaîne vide, alors le paramètre `spec` doit être `None`. Si aucun paramètre n'est fourni, AWS Glue essaie d'analyser le schéma et de l'utiliser pour résoudre les ambiguïtés.

Vous pouvez spécifier l'une des stratégies de résolution suivantes dans la portion `action` d'un tuple `specs` :

- `cast` – Vous permet de spécifier un type pour la conversion (par exemple, `cast:int`).
- `make_cols` – Résout une ambiguïté potentielle en aplatissant les données. Par exemple, si `columnA` peut être un `int` ou un `string`, la résolution doit produire deux colonnes nommées `columnA_int` et `columnA_string` dans le `DynamicFrame` obtenu.

- `make_struct` – Résout une ambiguïté potentielle en utilisant un champ struct pour représenter les données. Par exemple, si des données d'une colonne peuvent être un `int` ou un `string`, l'action `make_struct` produit une colonne de structures dans le `DynamicFrame` obtenu, chacune contenant à la fois un `int` et un `string`.
- `project` – Résout une éventuelle ambiguïté en conservant uniquement les valeurs d'un type spécifié dans l'image `DynamicFrame` obtenue. Par exemple, si les données d'une colonne `ChoiceType` peuvent être de type `int` ou `string`, la spécification d'une action `project:string` supprime des valeurs de l'image `DynamicFrame` obtenue qui ne sont pas de type `string`.

Si le path identifie un tableau, placez des crochets vides après le nom du tableau pour éviter toute ambiguïté. Par exemple, supposons que vous travailliez avec les données structurées comme suit :

```
"myList": [  
  { "price": 100.00 },  
  { "price": "$100.00" }  
]
```

Vous pouvez sélectionner la version numérique plutôt que la version chaîne du prix en définissant path sur `"myList[].price"` et action sur `"cast:double"`.

- `choice` – action de résolution par défaut si le paramètre `specs` est `None`. Si le paramètre `specs` n'est pas `None`, alors la seule valeur définie doit être une chaîne vide.

En plus des actions `specs` répertoriées précédemment, cet argument prend également en charge l'action suivante :

- `MATCH_CATALOG` – tente de convertir chaque `ChoiceType` dans le type correspondant de table Data Catalog spécifiée.
- `database`— La base de données AWS Glue Data Catalog à utiliser avec le `MATCH_CATALOG` choix (obligatoire pour `MATCH_CATALOG`).
- `table_name`— Le nom de la table AWS Glue Data Catalog à utiliser avec l'`MATCH_CATALOG` action (obligatoire pour `MATCH_CATALOG`).
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée. (facultatif) La valeur par défaut est zéro.

- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté. (facultatif) La valeur par défaut est zéro.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

`describe(cls)`

Hérité de `GlueTransform` [describe](#).

SelectFields classe

SelectFieldsLa classe crée une nouvelleDynamicFrameà partir d'unDynamicFrame, et ne conserve que les champs que vous spécifiez.SelectFieldsfournit des fonctionnalités similaires à celles d'un SQLSELECTinstructions.

exemple

Nous vous recommandons d'utiliser la[DynamicFrame.select_fields\(\)](#)méthode pour sélectionner des champs d'unDynamicFrame. Vous trouverez un exemple de code, consultez

Exemple : utilisez `select_fields` pour créer un nouveau `DynamicFrame` avec les champs sélectionnés.

Méthodes

- [`\_\_call\_\_`](#)
- [`s'appliquent`](#)
- [`name`](#)
- [`describeArgs`](#)
- [`describeReturn`](#)
- [`describeTransform`](#)
- [`describeErrors`](#)
- [`Describe`](#)

`__call__(frame, paths, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)`

Obtient les champs (nœuds) d'un `DynamicFrame`.

- `frame` – Objet `DynamicFrame` dans lequel sélectionner les champs (requis).
- `paths` – Liste des chemins complets vers les champs à sélectionner (obligatoire).
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.

Renvoie un nouvel objet `DynamicFrame` contenant uniquement les champs spécifiés.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [`s'appliquent`](#).

`name(cls)`

Hérité de `GlueTransform` [`name`](#).

describeArgs(cls)

Hérité de GlueTransform [describeArgs](#).

describeReturn(cls)

Hérité de GlueTransform [describeReturn](#).

describeTransform(cls)

Hérité de GlueTransform [describeTransform](#).

describeErrors(cls)

Hérité de GlueTransform [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

SelectFromCollection classe

Sélectionne un DynamicFrame dans un DynamicFrameCollection.

exemple

Cet exemple utilise SelectFromCollection pour sélectionner une image DynamicFrame dans une collection DynamicFrameCollection.

Exemple de jeu de données

L'exemple sélectionne deux images DynamicFrames d'une collection DynamicFrameCollection appelée split_rows_collection. Vous trouverez ci-dessous la liste des clés de la collection split_rows_collection.

```
dict_keys(['high', 'low'])
```

Exemple de code

```
# Example: Use SelectFromCollection to select  
# DynamicFrames from a DynamicFrameCollection
```

```

from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.transforms import SelectFromCollection

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Select frames and inspect entries
frame_low = SelectFromCollection.apply(dfc=split_rows_collection, key="low")
frame_low.toDF().show()

frame_high = SelectFromCollection.apply(dfc=split_rows_collection, key="high")
frame_high.toDF().show()

```

Sortie

```

+---+-----+-----+-----+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----+-----+
| 1| 0|fax|202-225-3307|
| 1| 1|phone|202-225-5731|
| 2| 0|fax|202-225-3307|
| 2| 1|phone|202-225-5731|
| 3| 0|fax|202-225-3307|
| 3| 1|phone|202-225-5731|
| 4| 0|fax|202-225-3307|
| 4| 1|phone|202-225-5731|
| 5| 0|fax|202-225-3307|
| 5| 1|phone|202-225-5731|
| 6| 0|fax|202-225-3307|
| 6| 1|phone|202-225-5731|
| 7| 0|fax|202-225-3307|
| 7| 1|phone|202-225-5731|
| 8| 0|fax|202-225-3307|
| 8| 1|phone|202-225-5731|
| 9| 0|fax|202-225-3307|
| 9| 1|phone|202-225-5731|
| 10| 0|fax|202-225-6328|
| 10| 1|phone|202-225-4576|
+---+-----+-----+-----+
only showing top 20 rows

```

```

+---+-----+-----+-----+-----+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----+-----+
| 11|  0|          fax|          202-225-6328|
| 11|  1|          phone|          202-225-4576|
| 11|  2|        twitter|      RepTrentFranks|
| 12|  0|          fax|          202-225-6328|
| 12|  1|          phone|          202-225-4576|
| 12|  2|        twitter|      RepTrentFranks|
| 13|  0|          fax|          202-225-6328|
| 13|  1|          phone|          202-225-4576|
| 13|  2|        twitter|      RepTrentFranks|
| 14|  0|          fax|          202-225-6328|
| 14|  1|          phone|          202-225-4576|
| 14|  2|        twitter|      RepTrentFranks|
| 15|  0|          fax|          202-225-6328|
| 15|  1|          phone|          202-225-4576|
| 15|  2|        twitter|      RepTrentFranks|
| 16|  0|          fax|          202-225-6328|
| 16|  1|          phone|          202-225-4576|
| 16|  2|        twitter|      RepTrentFranks|
| 17|  0|          fax|          202-225-6328|
| 17|  1|          phone|          202-225-4576|
+---+-----+-----+-----+
only showing top 20 rows

```

Méthodes

- [call](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

```
__call__(dfc, key, transformation_ctx = "")
```

Obtient un `DynamicFrame` d'un `DynamicFrameCollection`.

- `dfc` – Collection `DynamicFrameCollection` à partir de laquelle l'image `DynamicFrame` doit être sélectionnée (obligatoire).
- `key` – Clé du `DynamicFrame` à sélectionner (obligatoire).
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).

```
apply(cls, *args, **kwargs)
```

Hérité de `GlueTransform` [s'appliquent](#).

```
name(cls)
```

Hérité de `GlueTransform` [name](#).

```
describeArgs(cls)
```

Hérité de `GlueTransform` [describeArgs](#).

```
describeReturn(cls)
```

Hérité de `GlueTransform` [describeReturn](#).

```
describeTransform(cls)
```

Hérité de `GlueTransform` [describeTransform](#).

```
describeErrors(cls)
```

Hérité de `GlueTransform` [describeErrors](#).

```
describe(cls)
```

Hérité de `GlueTransform` [describe](#).

Classe `Simplify_DDB_JSON`

Simplifie les colonnes imbriquées `DynamicFrame` qui se trouvent spécifiquement dans la structure JSON DynamoDB et renvoie une nouvelle colonne simplifiée. `DynamicFrame`

exemple

Nous vous recommandons d'utiliser cette `DynamicFrame.simplify_ddb_json()` méthode pour simplifier les colonnes imbriquées dans un fichier `DynamicFrame` qui se trouve spécifiquement dans la structure JSON de DynamoDB. Vous trouverez un exemple de code, consultez [Exemple : utilisez simplify_ddb_json pour appeler un DynamoDB JSON simplify](#).

Classe Spigot

Écrit des exemples d'enregistrements vers une destination spécifiée pour vous aider à vérifier les transformations effectuées par votre AWS Glue travail.

exemple

Nous vous recommandons d'utiliser la méthode [DynamicFrame.spigot\(\)](#) pour écrire un sous-ensemble d'enregistrements depuis une image `DynamicFrame` vers une destination spécifiée. Vous trouverez un exemple de code, consultez [Exemple : utiliser la méthode spigot pour écrire des exemples de champs d'une image DynamicFrame vers Amazon S3](#).

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

`__call__(trame, chemin, options, transformation_ctx = "")`

Écrit des exemples d'enregistrements sur une destination spécifiée au cours d'une transformation.

- `frame` - `DynamicFrame` sur lequel effectuer le spigot (requis).
- `path` – Chemin d'accès de la destination sur laquelle écrire (obligatoire).
- `options` – Paires clé-valeur JSON spécifiant des options (facultatif). L'option "topk" indique que les premiers enregistrements k doivent être écrits. L'option "prob" indique la probabilité

(sous forme de décimale) de sélectionner un enregistrement donné. Utilisée pour sélectionner les enregistrements à écrire.

- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#)

`name(cls)`

Hérité de `GlueTransform` [name](#)

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#)

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#)

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#)

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#)

`describe(cls)`

Hérité de `GlueTransform` [describe](#)

`SplitFields` classe

Fractionne un `DynamicFrame` en deux, en fonction des champs spécifiés.

exemple

Nous vous recommandons d'utiliser la méthode [DynamicFrame.split_fields\(\)](#) pour fractionner les champs en image `DynamicFrame`. Vous trouverez un exemple de code, consultez

Exemple : utiliser la méthode `split_fields` pour fractionner les champs sélectionnés en une image `DynamicFrame` distincte.

Méthodes

- [`\_\_call\_\_`](#)
- [`s'appliquent`](#)
- [`name`](#)
- [`describeArgs`](#)
- [`describeReturn`](#)
- [`describeTransform`](#)
- [`describeErrors`](#)
- [`describe`](#)

```
__call__(frame, paths, name1 = None, name2 = None, transformation_ctx = "", info = "",  
stageThreshold = 0, totalThreshold = 0)
```

Fractionne un ou plusieurs champs d'une image `DynamicFrame` en une nouvelle image `DynamicFrame` et crée une autre nouvelle image `DynamicFrame` contenant les champs restants.

- `frame` – `DynamicFrame` source à scinder en deux nouveaux objets (obligatoire).
- `paths` – Liste des chemins complets vers les champs à fractionner (obligatoire).
- `name1` – nom à attribuer au `DynamicFrame` qui contiendra les champs à fractionner (facultatif). Si aucun nom n'est fourni, le nom de la trame source est utilisé, « 1 » étant ajouté.
- `name2` – nom à attribuer au `DynamicFrame` qui contient les champs qui restent après le fractionnement des champs spécifiés (facultatif). Si aucun nom n'est fourni, le nom de la trame source est utilisé, « 2 » étant ajouté.
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

`describe(cls)`

Hérité de `GlueTransform` [describe](#).

`SplitRows` classe

Crée une collection `DynamicFrameCollection` qui contient deux images `DynamicFrames`. Une image `DynamicFrame` contient uniquement les champs spécifiés à fractionner et l'autre contient les champs restants.

exemple

Nous vous recommandons d'utiliser la méthode [DynamicFrame.split_rows\(\)](#) pour fractionner les lignes en image `DynamicFrame`. Vous trouverez un exemple de code, consultez [Exemple : utiliser la méthode split_rows pour fractionner des lignes en une image DynamicFrame](#).

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)

- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

`__call__(frame, comparison_dict, name1="frame1", name2="frame2", transformation_ctx = "", info = None, stageThreshold = 0, totalThreshold = 0)`

Scinde une ou plusieurs lignes d'un objet `DynamicFrame` en un nouveau `DynamicFrame`.

- `frame` – `DynamicFrame` source à scinder en deux nouveaux objets (obligatoire).
- `comparison_dict` – Dictionnaire dans lequel la clé est le chemin d'accès complet à une colonne et la valeur est un autre dictionnaire permettant de mapper les comparateurs aux valeurs auxquelles les valeurs de la colonne sont comparées. Par exemple, `{"age": {">": 10, "<": 20}}` scinde les lignes où la valeur de « age » est comprise entre 10 et 20 (exclus), à partir des lignes où « age » est en dehors de la plage (obligatoire).
- `name1` – Nom à attribuer à l'objet `DynamicFrame` qui contient les lignes à scinder (facultatif).
- `name2` - Nom à attribuer à l'objet `DynamicFrame` qui contient les lignes qui restent après que les lignes spécifiées ont été scindées (facultatif).
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

describeArgs(cls)

Hérité de GlueTransform [describeArgs](#).

describeReturn(cls)

Hérité de GlueTransform [describeReturn](#).

describeTransform(cls)

Hérité de GlueTransform [describeTransform](#).

describeErrors(cls)

Hérité de GlueTransform [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

Classe Unbox

Effectue une opération unbox sur un champ de chaîne (ou le reformate) dans une image DynamicFrame.

exemple

Nous vous recommandons d'utiliser la méthode [DynamicFrame.unbox\(\)](#) pour effectuer une opération unbox sur un champ dans une image DynamicFrame. Vous trouverez un exemple de code, consultez [Exemple : utiliser la méthode unbox pour effectuer une opération unbox sur un champ de chaîne en un champ struct](#).

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)

- [describe](#)

```
__call__(frame, path, format, transformation_ctx = "", info="", stageThreshold=0, totalThreshold=0,
**options)
```

Effectue une opération unbox sur un champ de chaîne dans un `DynamicFrame`.

- `frame` – `DynamicFrame` dans lequel effectuer une opération unbox sur un champ (obligatoire).
- `path` - Chemin d'accès complet au `StringNode` sur lequel effectuer une opération unbox (obligatoire).
- `format` – spécification de format (facultatif). Ceci est utilisé pour un Amazon S3 ou AWS Glue connexion qui prend en charge plusieurs formats. Consultez [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#) pour connaître les formats pris en charge.
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.
- `separator` - Jeton de séparateur (facultatif).
- `escaper` – Jeton d'échappement (facultatif).
- `skipFirst` - `True` si la première ligne de données doit être ignorée, ou `False` dans le cas contraire (facultatif).
- `withSchema` – Chaîne contenant un schéma pour les données sur lesquelles effectuer l'opération unbox (facultatif). Doit toujours être créée à l'aide de `StructType.json`.
- `withHeader` - `True` si les données à décompresser comprennent un en-tête, ou `False` dans le cas contraire (facultatif).

```
apply(cls, *args, **kwargs)
```

Hérité de `GlueTransform` [s'appliquent](#).

```
name(cls)
```

Hérité de `GlueTransform` [name](#).

describeArgs(cls)

Hérité de GlueTransform [describeArgs](#).

describeReturn(cls)

Hérité de GlueTransform [describeReturn](#).

describeTransform(cls)

Hérité de GlueTransform [describeTransform](#).

describeErrors(cls)

Hérité de GlueTransform [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

UnnestFrame classe

Désimbrique une image DynamicFrame, aplatit les objets imbriqués en éléments de niveau supérieur et génère les clés de jointure pour les objets de tableau.

exemple

Nous vous recommandons d'utiliser la méthode [DynamicFrame.unnest\(\)](#) pour aplatir les structures imbriquées dans une image DynamicFrame. Vous trouverez un exemple de code, consultez [Exemple : utiliser la méthode unnest pour transformer des champs imbriqués en champs de niveau supérieur](#).

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)

- [describe](#)

`__call__(frame, transformation_ctx = "", info="", stageThreshold=0, totalThreshold=0)`

Désimbrique une image `DynamicFrame`, aplatit les objets imbriqués en éléments de niveau supérieur et génère les clés de jointure pour les objets de tableau.

- `frame` – Objet `DynamicFrame` à désimbriquer (requis).
- `transformation_ctx` – Chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- `info` – Chaîne associée à des erreurs dans la transformation (facultatif).
- `stageThreshold` – nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée.(facultatif) La valeur par défaut est zéro.
- `totalThreshold` – nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté.(facultatif) La valeur par défaut est zéro.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

FlagDuplicatesInColumn classe

La FlagDuplicatesInColumn transformation renvoie une nouvelle colonne avec une valeur spécifiée dans chaque ligne qui indique si la valeur de la colonne source de la ligne correspond à une valeur d'une ligne précédente de la colonne source. Lorsque des correspondances sont trouvées, elles sont signalées comme des doublons. L'occurrence initiale n'est pas signalée, car elle ne correspond pas à une ligne précédente.

exemple

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsglue.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

datasource1 = spark.read.json("s3://${BUCKET}/json/zip/raw/data")

try:
    df_output = column.FlagDuplicatesInColumn.apply(
        data_frame=datasource1,
        spark_context=sc,
        source_column="city",
        target_column="flag_col",
        true_string="True",
        false_string="False"
    )
except:
    print("Unexpected Error happened ")
    raise
```

Sortie

La FlagDuplicatesInColumn transformation ajoutera une nouvelle colonne `flag\_col` à la `df\_output`. DataFrame Cette colonne contiendra une valeur de chaîne indiquant si la ligne correspondante possède une valeur dupliquée dans la colonne « ville » ou non. Si une ligne contient

une valeur `city` dupliquée, le `flag\_col` contiendra la valeur `true\_string` « True ». Si une ligne possède une valeur `city` unique, le `flag\_col` contiendra la valeur `false\_string` « False ».

Le `df\_output` qui en DataFrame résultera contiendra toutes les colonnes du `datasource1` original, plus la colonne `flag\_col` supplémentaire indiquant les valeurs dupliquées de `city`. DataFrame

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

`__call__` (spark_context, data_frame, source_column, target_column, true_string=default_true_string, false_string=default_false_string)

La FlagDuplicatesInColumn transformation renvoie une nouvelle colonne avec une valeur spécifiée dans chaque ligne qui indique si la valeur de la colonne source de la ligne correspond à une valeur d'une ligne précédente de la colonne source. Lorsque des correspondances sont trouvées, elles sont signalées comme des doublons. L'occurrence initiale n'est pas signalée, car elle ne correspond pas à une ligne précédente.

- `source_column`— Nom de la colonne source.
- `target_column`— Nom de la colonne cible.
- `true_string`— Chaîne à insérer dans la colonne cible lorsqu'une valeur de colonne source duplique une valeur antérieure dans cette colonne.
- `false_string`— Chaîne à insérer dans la colonne cible lorsqu'une valeur de colonne source est différente des valeurs précédentes de cette colonne.

`apply(cls, *args, **kwargs)`

Hérité de GlueTransform [s'appliquent](#).

name(cls)

Hérité de GlueTransform [name](#).

describeArgs(cls)

Hérité de GlueTransform [describeArgs](#).

describeReturn(cls)

Hérité de GlueTransform [describeReturn](#).

describeTransform(cls)

Hérité de GlueTransform [describeTransform](#).

describeErrors(cls)

Hérité de GlueTransform [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

FormatPhoneNumber classe

La FormatPhoneNumber transformation renvoie une colonne dans laquelle une chaîne de numéro de téléphone est convertie en valeur formatée.

exemple

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsglue.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
    [
        ("408-341-5669",),
        ("4083415669",)
```

```
    ],  
    ["phone"],  
)  
  
try:  
    df_output = column_formatting.FormatPhoneNumber.apply(  
        data_frame=input_df,  
        spark_context=sc,  
        source_column="phone",  
        default_region="US"  
    )  
    df_output.show()  
except:  
    print("Unexpected Error happened ")  
    raise
```

Sortie

Le résultat sera :

```
```\n+-----+\n| phone|\n+-----+\n|(408) 341-5669|\n|(408) 341-5669|\n+-----+\n```\n
```

La `FormatPhoneNumber` transformation prend le `source_column` comme `"phone"` et le `default_region` comme `"US"`.

La transformation permet de formater avec succès les deux numéros de téléphone, quel que soit leur format initial, au format américain standard `“(408) 341-5669”`.

## Méthodes

- [call](#)
- [s'appliquent](#)
- [name](#)

- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

`__call__` (spark\_context, data\_frame, source\_column, phone\_number\_format=None, default\_region=None, default\_region\_column=None)

La `FormatPhoneNumber` transformation renvoie une colonne dans laquelle une chaîne de numéro de téléphone est convertie en valeur formatée.

- `source_column` : nom d'une colonne existante.
- `phone_number_format`— Le format dans lequel convertir le numéro de téléphone. Si aucun format n'est spécifié, le format par défaut est `E.164` un format de numéro de téléphone standard reconnu à l'échelle internationale. Les valeurs valides sont notamment les suivantes :
  - `E164` (omettre le point après `E`)
- `default_region`— Un code de région valide composé de deux ou trois lettres majuscules qui indique la région du numéro de téléphone lorsqu'aucun code de pays n'est présent dans le numéro lui-même. Tout au plus, l'un `defaultRegion` des `defaultRegionColumn` deux peut être fourni.
- `default_region_column`— Le nom d'une colonne de type de données avancé `Country`. Le code de région de la colonne spécifiée est utilisé pour déterminer le code de pays pour le numéro de téléphone lorsqu'aucun code de pays n'est présent dans le numéro lui-même. Tout au plus, l'un `defaultRegion` des `defaultRegionColumn` deux peut être fourni.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

describeReturn(cls)

Hérité de GlueTransform [describeReturn](#).

describeTransform(cls)

Hérité de GlueTransform [describeTransform](#).

describeErrors(cls)

Hérité de GlueTransform [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

FormatCase classe

La FormatCase transformation remplace chaque chaîne d'une colonne par le type de majuscule spécifié.

exemple

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsglue.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

datasource1 = spark.read.json("s3://${BUCKET}/json/zips/raw/data")

try:
 df_output = data_cleaning.FormatCase.apply(
 data_frame=datasource1,
 spark_context=sc,
 source_column="city",
 case_type="LOWER"
)
except:
 print("Unexpected Error happened ")
 raise
```

## Sortie

La `FormatCase` transformation convertira les valeurs de la colonne « city » en minuscules en fonction du paramètre « `CASE_TYPE="LOWER"` ». Le ``df_output`` qui en `DataFrame` résultera contiendra toutes les colonnes du ``datasource1`` original, mais avec les valeurs des colonnes ``city`` `DataFrame` en minuscules.

## Méthodes

- [`\_\_call\_\_`](#)
- [`s'appliquent`](#)
- [`name`](#)
- [`describeArgs`](#)
- [`describeReturn`](#)
- [`describeTransform`](#)
- [`describeErrors`](#)
- [`describe`](#)

`__call__` (spark\_context, data\_frame, source\_column, cas\_type)

La `FormatCase` transformation remplace chaque chaîne d'une colonne par le type de majuscule spécifié.

- `source_column` : nom d'une colonne existante.
- `case_type`— Les types de boîtiers pris en charge sont `CAPITALLOWER`, `UPPER`, `SENTENCE`.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [`s'appliquent`](#).

`name(cls)`

Hérité de `GlueTransform` [`name`](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [`describeArgs`](#).

describeReturn(cls)

Hérité de GlueTransform [describeReturn](#).

describeTransform(cls)

Hérité de GlueTransform [describeTransform](#).

describeErrors(cls)

Hérité de GlueTransform [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

FillWithMode classe

La FillWithMode transformation met en forme une colonne en fonction du format de numéro de téléphone que vous spécifiez. Vous pouvez également définir une logique de rupture d'égalité, dans laquelle certaines valeurs sont identiques. Par exemple, considérez les valeurs suivantes : 1 2 2 3 3 4

Un ModeType de MINIMUM entraîne le renvoi FillWithMode de 2 comme valeur de mode. Si ModeType est défini sur 3MAXIMUM, le mode est 3. Car AVERAGE le mode est 2,5.

exemple

```
from awsglue.context import *
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
 [
 (105.111, 13.12),
 (1055.123, 13.12),
 (None, 13.12),
 (13.12, 13.12),
 (None, 13.12),
],
 ["source_column_1", "source_column_2"],
```

```

)

try:
 df_output = data_quality.FillWithMode.apply(
 data_frame=input_df,
 spark_context=sc,
 source_column="source_column_1",
 mode_type="MAXIMUM"
)
 df_output.show()
except:
 print("Unexpected Error happened ")
 raise

```

## Sortie

La sortie du code donné sera :

```

...
+-----+-----+
|source_column_1|source_column_2|
+-----+-----+
| 105.111| 13.12|
| 1055.123| 13.12|
| 1055.123| 13.12|
| 13.12| 13.12|
| 1055.123| 13.12|
+-----+-----+
...

```

La `FillWithMode` transformation du module `aws glue.data_quality` est appliquée au `input_df`. `DataFrame` Il remplace les valeurs « nulles » de la `source_column_1` colonne par la valeur maximale (`MODE_TYPE="MAXIMUM"`) parmi les valeurs non nulles de cette colonne.

Dans ce cas, la valeur maximale de la `source_column_1` colonne est « 1055,123 ». Par conséquent, les valeurs `null` `source_column_1` sont remplacées par `1055,123` dans la sortie `df_output`. `DataFrame`

## Méthodes

- [call](#)

- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

`__call__ (spark_context, data_frame, source_column, mode_type)`

La FillWithMode transformation met en forme le cas de chaînes dans une colonne.

- `source_column` : nom d'une colonne existante.
- `mode_type`— Comment résoudre les valeurs d'égalité dans les données. Cette valeur doit être l'une des valeurs suivantes : MINIMUM NONEAVERAGE, ou MAXIMUM.

`apply(cls, *args, **kwargs)`

Hérité de GlueTransform [s'appliquent](#).

`name(cls)`

Hérité de GlueTransform [name](#).

`describeArgs(cls)`

Hérité de GlueTransform [describeArgs](#).

`describeReturn(cls)`

Hérité de GlueTransform [describeReturn](#).

`describeTransform(cls)`

Hérité de GlueTransform [describeTransform](#).

`describeErrors(cls)`

Hérité de GlueTransform [describeErrors](#).



describe(cls)

Hérité de GlueTransform [describe](#).

FlagDuplicateRows classe

La FlagDuplicateRows transformation renvoie une nouvelle colonne avec une valeur spécifiée dans chaque ligne qui indique si cette ligne correspond exactement à une ligne précédente de l'ensemble de données. Lorsque des correspondances sont trouvées, elles sont signalées comme des doublons. L'occurrence initiale n'est pas signalée, car elle ne correspond pas à une ligne précédente.

exemple

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsglue.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
 [
 (105.111, 13.12),
 (13.12, 13.12),
 (None, 13.12),
 (13.12, 13.12),
 (None, 13.12),
],
 ["source_column_1", "source_column_2"],
)

try:
 df_output = data_quality.FlagDuplicateRows.apply(
 data_frame=input_df,
 spark_context=sc,
 target_column="flag_row",
 true_string="True",
 false_string="False",
 target_index=1
)
except:
 print("Unexpected Error happened ")
```

```
raise
```

## Sortie

La sortie sera une PySpark DataFrame avec une colonne supplémentaire `flag_row` qui indique si une ligne est un doublon ou non, en fonction de la `source_column_1` colonne. Le fichier ``df_output`` qui en résultera DataFrame contiendra les lignes suivantes :

```

'''
+-----+-----+-----+
|source_column_1|source_column_2|flag_row|
+-----+-----+-----+
| 105.111| 13.12| False|
| 13.12| 13.12| True|
| null| 13.12| True|
| 13.12| 13.12| True|
| null| 13.12| True|
+-----+-----+-----+
'''

```

La `flag_row` colonne indique si une ligne est un doublon ou non. Le ``true_string`` est défini sur « True », et le ``false_string`` est défini sur « False ». Le ``target_index`` est défini sur 1, ce qui signifie que la `flag_row` colonne sera insérée à la deuxième position (index 1) dans la sortie. DataFrame

## Méthodes

- [`\_\_call\_\_`](#)
- [`s'appliquent`](#)
- [`name`](#)
- [`describeArgs`](#)
- [`describeReturn`](#)
- [`describeTransform`](#)
- [`describeErrors`](#)
- [`describe`](#)

`__call__` (spark\_context, data\_frame, target\_column, true\_string=DEFAULT\_TRUE\_STRING, FALSE\_STRING=DEFAULT\_FALSE\_STRING, TARGET\_INDEX=NONE)

La `FlagDuplicateRows` transformation renvoie une nouvelle colonne avec une valeur spécifiée dans chaque ligne qui indique si cette ligne correspond exactement à une ligne précédente de l'ensemble de données. Lorsque des correspondances sont trouvées, elles sont signalées comme des doublons. L'occurrence initiale n'est pas signalée, car elle ne correspond pas à une ligne précédente.

- `true_string`— Valeur à insérer si la ligne correspond à une ligne précédente.
- `false_string`— Valeur à insérer si la ligne est unique.
- `target_column`— Nom de la nouvelle colonne insérée dans le jeu de données.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

`describe(cls)`

Hérité de `GlueTransform` [describe](#).

## RemoveDuplicates classe

La RemoveDuplicates transformation supprime une ligne entière si une valeur dupliquée est détectée dans une colonne source sélectionnée.

### exemple

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsglue.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
 [
 (105.111, 13.12),
 (13.12, 13.12),
 (None, 13.12),
 (13.12, 13.12),
 (None, 13.12),
],
 ["source_column_1", "source_column_2"],
)

try:
 df_output = data_quality.RemoveDuplicates.apply(
 data_frame=input_df,
 spark_context=sc,
 source_column="source_column_1"
)
except:
 print("Unexpected Error happened ")
 raise
```

### Sortie

Le résultat sera un PySpark DataFrame avec les doublons supprimés en fonction de la source\_column\_1 colonne. Le fichier `df\_output` qui en résultera DataFrame contiendra les lignes suivantes :

...

```
+-----+-----+
|source_column_1|source_column_2|
+-----+-----+
| 105.111| 13.12|
| 13.12| 13.12|
| null| 13.12|
+-----+-----+
...
```

Notez que les lignes avec les `source_column_1` valeurs « 13.12 » et « null » n'apparaissent qu'une seule fois dans la sortie DataFrame, car les doublons ont été supprimés en fonction de la colonne.

`source_column_1`

## Méthodes

- [\\_\\_call\\_\\_](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

`__call__` (spark\_context, data\_frame, source\_column)

La `RemoveDuplicates` transformation supprime une ligne entière si une valeur dupliquée est détectée dans une colonne source sélectionnée.

- `source_column` : nom d'une colonne existante.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

describeArgs(cls)

Hérité de GlueTransform [describeArgs](#).

describeReturn(cls)

Hérité de GlueTransform [describeReturn](#).

describeTransform(cls)

Hérité de GlueTransform [describeTransform](#).

describeErrors(cls)

Hérité de GlueTransform [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

MonthName classe

La MonthName transformation crée une nouvelle colonne contenant le nom du mois, à partir d'une chaîne représentant une date.

exemple

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsglue.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

spark.conf.set("spark.sql.legacy.timeParserPolicy", "LEGACY")

input_df = spark.createDataFrame(
 [
 ("20-2018-12",),
 ("2018-20-12",),
 ("20182012",),
 ("12202018",),
 ("20122018",),
]
)
```

```

 ("20-12-2018",),
 ("12/20/2018",),
 ("02/02/02",),
 ("02 02 2009",),
 ("02/02/2009",),
 ("August/02/2009",),
 ("02/june/2009",),
 ("02/2020/june",),
 ("2013-02-21 06:35:45.658505",),
 ("August 02 2009",),
 ("2013/02/21",),
 (None,),
],
 ["column_1"],
)

try:
 df_output = datetime_functions.MonthName.apply(
 data_frame=input_df,
 spark_context=sc,
 source_column="column_1",
 target_column="target_column"
)
 df_output.show()
except:
 print("Unexpected Error happened ")
 raise

```

## Sortie

Le résultat sera :

```

...
+-----+-----+
| column_1|target_column|
+-----+-----+
|20-2018-12 | December |
|2018-20-12 | null |
| 20182012| null |
| 12202018| null |
| 20122018| null |
|20-12-2018 | December |
|12/20/2018 | December |

```

```
| 02/02/02 | February |
|02 02 2009 | February |
|02/02/2009 | February |
|August/02/2009| August |
|02/june/2009| null |
|02/2020/june| null |
|2013-02-21 06:35:45.658505| February |
|August 02 2009| August |
| 2013/02/21| February |
| null | null |
+-----+-----+
` ``
```

La `MonthName` transformation prend la `source_column` comme `"column_1"` et la `target_column` comme `"target_column"`. Il tente d'extraire le nom du mois de la date/time strings in the `"column_1"` column and places it in the `"target_column"` column. If the date/time chaîne si son format n'est pas reconnu ou ne peut pas être analysé, la valeur de `target_column` est définie sur `null`.

La transformation extrait avec succès le nom du mois à partir de différents formats de date/heure, tels que `« 20-12-2018 »`, `« 20/12/2018 »`, `« 02/02/2009 »`, `« 2013-02-21 06:35:45.658 505 »` et `« 02 août 2009 »`.

## Méthodes

- [\\_\\_call\\_\\_](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

`__call__` (spark\_context, data\_frame, target\_column, source\_column=None, value=None)

La `MonthName` transformation crée une nouvelle colonne contenant le nom du mois, à partir d'une chaîne représentant une date.



- `source_column` : nom d'une colonne existante.
- `value`— Une chaîne de caractères à évaluer.
- `target_column`— Nom de la colonne nouvellement créée.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

`describe(cls)`

Hérité de `GlueTransform` [describe](#).

IsEven classe

La IsEven transformation renvoie une valeur booléenne dans une nouvelle colonne qui indique si la colonne ou la valeur source est paire. Si la colonne ou la valeur source est décimale, le résultat est faux.

exemple

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsglue.transforms import *
```

```

sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
 [(5,), (0,), (-1,), (2,), (None,)],
 ["source_column"],
)

try:
 df_output = math_functions.IsEven.apply(
 data_frame=input_df,
 spark_context=sc,
 source_column="source_column",
 target_column="target_column",
 value=None,
 true_string="Even",
 false_string="Not even",
)
 df_output.show()
except:
 print("Unexpected Error happened ")
 raise

```

## Sortie

Le résultat sera :

```

...
+-----+-----+
|source_column|target_column|
+-----+-----+
| 5| Not even|
| 0| Even|
| -1| Not even|
| 2| Even|
| null| null|
+-----+-----+
...

```

La `IsEven` transformation prend la ``source_column`` comme « `source_column` » et la ``target_column`` comme « `target_column` ». Il vérifie si la valeur de la ``source_column`` est paire ou non. Si la valeur

est paire, elle donne à la valeur « target\_column » la valeur « Even » de « true\_string ». Si la valeur est impaire, elle donne à la valeur « target\_column » la valeur « Pas pair » pour « false\_string ». Si la valeur de la "source\_column" est `null`, la valeur de "target\_column" est définie sur `null`.

La transformation identifie correctement les nombres pairs (0 et 2) et définit la valeur de « target\_column » sur « Even ». Pour les nombres impairs (5 et -1), il définit la valeur « Target\_column » sur « Pas pair ». Pour la valeur `null` dans "source\_column", la valeur "target\_column" est définie sur `null`.

## Méthodes

- [\\_\\_call\\_\\_](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

`__call__` (spark\_context, data\_frame, target\_column, source\_column=None, true\_string=DEFAULT\_TRUE\_STRING, FALSE\_STRING=DEFAULT\_FALSE\_STRING, value=None)

La IsEven transformation renvoie une valeur booléenne dans une nouvelle colonne qui indique si la colonne ou la valeur source est paire. Si la colonne ou la valeur source est décimale, le résultat est faux.

- source\_column : nom d'une colonne existante.
- target\_column— Nom de la nouvelle colonne à créer.
- true\_string— Chaîne indiquant si la valeur est paire.
- false\_string— Chaîne indiquant si la valeur n'est pas paire.

`apply(cls, *args, **kwargs)`

Hérité de GlueTransform [s'appliquent](#).

name(cls)

Hérité de GlueTransform [name](#).

describeArgs(cls)

Hérité de GlueTransform [describeArgs](#).

describeReturn(cls)

Hérité de GlueTransform [describeReturn](#).

describeTransform(cls)

Hérité de GlueTransform [describeTransform](#).

describeErrors(cls)

Hérité de GlueTransform [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

CryptographicHash classe

La CryptographicHash transformation applique un algorithme aux valeurs de hachage de la colonne.

exemple

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsglue.transforms import *

secret = "${SECRET}"
sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
 [
 (1, "1234560000"),
 (2, "1234560001"),
```

```

 (3, "1234560002"),
 (4, "1234560003"),
 (5, "1234560004"),
 (6, "1234560005"),
 (7, "1234560006"),
 (8, "1234560007"),
 (9, "1234560008"),
 (10, "1234560009"),
],
 ["id", "phone"],
)

try:
 df_output = pii.CryptographicHash.apply(
 data_frame=input_df,
 spark_context=sc,
 source_columns=["id", "phone"],
 secret_id=secret,
 algorithm="HMAC_SHA256",
 output_format="BASE64",
)
 df_output.show()
except:
 print("Unexpected Error happened ")
 raise

```

## Sortie

Le résultat sera :

```

...
+---+-----+-----+-----+
| id| phone | id_hashed | phone_hashed |
+---+-----+-----+-----+
| 1| 1234560000 | QUI1zXTJiXmfIb... | juDBAmiRnn03g... |
| 2| 1234560001 | ZAUWiZ3dVTzCo... | vC8lgUqBVDMNQ... |
| 3| 1234560002 | ZP4VvZWkqYifu... | K13QAkgsWYpzB... |
| 4| 1234560003 | 3u8v03wQ8EQfj... | CPBzK1P8PZZkV... |
| 5| 1234560004 | eWkQJk4zA0Izx... | aLf7+mHcXqbLs... |
| 6| 1234560005 | xtI9fZCJZCvsa... | dy2DFgdYWmr0p... |
| 7| 1234560006 | iW9hew7jnHu0f... | wwFGMC0Ev6o0v... |
| 8| 1234560007 | H9V1pqvgkFhfS... | g9WKhagIXy9ht... |
| 9| 1234560008 | xDhEuHaxAUbU5... | b3uQLKPY+Q5vU... |

```

```
| 10| 1234560009 | GRN6nFXkxk349... | VJdsKt8VbxBbt... |
+---+-----+-----+-----+
...

```

La transformation calcule les hachages cryptographiques des valeurs des colonnes « id » et « phone » à l'aide de l'algorithme et de la clé secrète spécifiés, et code les hachages au format Base64. Le `df_output` qui en résulte DataFrame contient toutes les colonnes du `input_df` original, plus les colonnes supplémentaires `id_hashed` et `phone_hashed` avec DataFrame les hachages calculés.

## Méthodes

- [`\_\_call\_\_`](#)
- [`s'appliquent`](#)
- [`name`](#)
- [`describeArgs`](#)
- [`describeReturn`](#)
- [`describeTransform`](#)
- [`describeErrors`](#)
- [`describe`](#)

`__call__` (spark\_context, data\_frame, source\_columns, secret\_id, algorithm=None, secret\_version=None, create\_secret\_if\_missing=False, output\_format=None, entity\_type\_filter=None)

La `CryptographicHash` transformation applique un algorithme aux valeurs de hachage de la colonne.

- `source_columns`— Un tableau de colonnes existantes.
- `secret_id`— L'ARN de la clé secrète de Secrets Manager. Clé utilisée dans l'algorithme de préfixe du code d'authentification des messages basé sur le hachage (HMAC) pour hacher les colonnes sources.
- `secret_version` : facultatif. Par défaut, c'est la dernière version secrète.
- `entity_type_filter`— Tableau facultatif de types d'entités. Peut être utilisé pour chiffrer uniquement les informations personnelles détectées dans une colonne de texte libre.
- `create_secret_if_missing`— Booléen facultatif. Si c'est vrai, il essaiera de créer le secret au nom de l'appelant.

- `algorithm`— L'algorithme utilisé pour hacher vos données. Valeurs d'énumération valides : MD5,, SHA1, HMAC\_ SHA256 SHA512, HMAC\_MD5, HMAC\_, HMAC\_SHA1. SHA256 SHA512

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

`describe(cls)`

Hérité de `GlueTransform` [describe](#).

Classe de déchiffrement

La Decrypt transformation déchiffre l'intérieur de Glue. AWS Vos données peuvent également être déchiffrées en dehors de AWS Glue avec le AWS SDK de chiffrement. Si l'ARN de la clé KMS fourni ne correspond pas à celui utilisé pour chiffrer la colonne, l'opération de déchiffrement échoue.

exemple

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsglue.transforms import *

kms = "${KMS}"
sc = SparkContext()
```

```
spark = SparkSession(sc)

input_df = spark.createDataFrame(
 [
 (1, "1234560000"),
 (2, "1234560001"),
 (3, "1234560002"),
 (4, "1234560003"),
 (5, "1234560004"),
 (6, "1234560005"),
 (7, "1234560006"),
 (8, "1234560007"),
 (9, "1234560008"),
 (10, "1234560009"),
],
 ["id", "phone"],
)

try:
 df_encrypt = pii.Encrypt.apply(
 data_frame=input_df,
 spark_context=sc,
 source_columns=["phone"],
 kms_key_arn=kms
)
 df_decrypt = pii.Decrypt.apply(
 data_frame=df_encrypt,
 spark_context=sc,
 source_columns=["phone"],
 kms_key_arn=kms
)
 df_decrypt.show()
except:
 print("Unexpected Error happened ")
 raise
```

## Sortie

La sortie sera une PySpark DataFrame avec la colonne « id » d'origine et la colonne « phone » déchiffrée :

...



```
+---+-----+
| id| phone|
+---+-----+
| 1| 1234560000|
| 2| 1234560001|
| 3| 1234560002|
| 4| 1234560003|
| 5| 1234560004|
| 6| 1234560005|
| 7| 1234560006|
| 8| 1234560007|
| 9| 1234560008|
| 10| 1234560009|
+---+-----+
```
```

La `Encrypt` transformation prend le `source_columns` comme `["phone"]` et le `kms_key_arn` comme valeur de la variable d'environnement `${KMS}`. La transformation chiffre les valeurs de la colonne « phone » à l'aide de la clé KMS spécifiée. Le `DataFrame` `df_encrypt` crypté est ensuite transmis à la `Decrypt` transformation depuis le module `awsglue.pii`. Il prend le `source_columns` comme `["phone"]` et le `kms_key_arn` comme valeur de la variable d'environnement `${KMS}`. La transformation déchiffre les valeurs chiffrées dans la colonne « phone » à l'aide de la même clé KMS. Le fichier `df_decrypt` qui en résulte `DataFrame` contient la colonne `id` d'origine et la colonne `phone` décryptée.

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

`__call__` (spark_context, data_frame, source_columns, kms_key_arn)

La Decrypt transformation déchiffre l'intérieur de Glue. AWS Vos données peuvent également être déchiffrées en dehors de AWS Glue avec le AWS SDK de chiffrement. Si l'ARN de la clé KMS fourni ne correspond pas à celui utilisé pour chiffrer la colonne, l'opération de déchiffrement échoue.

- `source_columns`— Un tableau de colonnes existantes.
- `kms_key_arn`— L'ARN de la AWS clé du service de gestion des clés à utiliser pour déchiffrer les colonnes source.

`apply(cls, *args, **kwargs)`

Hérité de GlueTransform [s'appliquent](#).

`name(cls)`

Hérité de GlueTransform [name](#).

`describeArgs(cls)`

Hérité de GlueTransform [describeArgs](#).

`describeReturn(cls)`

Hérité de GlueTransform [describeReturn](#).

`describeTransform(cls)`

Hérité de GlueTransform [describeTransform](#).

`describeErrors(cls)`

Hérité de GlueTransform [describeErrors](#).

`describe(cls)`

Hérité de GlueTransform [describe](#).

Classe de chiffrement

La Encrypt transformation chiffre les colonnes source à l'aide de la AWS clé du service de gestion des clés. La Encrypt transformation peut chiffrer jusqu'à 128 MiB par cellule. Il tentera de préserver

le format lors du déchiffrement. Pour préserver le type de données, les métadonnées du type de données doivent être sérialisées à moins de 1 Ko. Dans le cas contraire, vous devez définir le `preserve_data_type` paramètre sur `false`. Les métadonnées du type de données seront stockées en texte brut dans le contexte du chiffrement.

exemple

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsglue.transforms import *

kms = "${KMS}"
sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
    [
        (1, "1234560000"),
        (2, "1234560001"),
        (3, "1234560002"),
        (4, "1234560003"),
        (5, "1234560004"),
        (6, "1234560005"),
        (7, "1234560006"),
        (8, "1234560007"),
        (9, "1234560008"),
        (10, "1234560009"),
    ],
    ["id", "phone"],
)

try:
    df_encrypt = pii.Encrypt.apply(
        data_frame=input_df,
        spark_context=sc,
        source_columns=["phone"],
        kms_key_arn=kms
    )
except:
    print("Unexpected Error happened ")
    raise
```

Sortie

La sortie sera une PySpark DataFrame avec la colonne « id » d'origine et une colonne supplémentaire contenant les valeurs cryptées de la colonne « phone ».

```

...
+---+-----+-----+
| id| phone | phone_encrypted |
+---+-----+-----+
1	1234560000	EncryptedData1234...abc
2	1234560001	EncryptedData5678...def
3	1234560002	EncryptedData9012...ghi
4	1234560003	EncryptedData3456...jkl
5	1234560004	EncryptedData7890...mno
6	1234560005	EncryptedData1234...pqr
7	1234560006	EncryptedData5678...stu
8	1234560007	EncryptedData9012...vwx
9	1234560008	EncryptedData3456...yz0
10	1234560009	EncryptedData7890...123
+---+-----+-----+
...

```

La `Encrypt` transformation prend le `source_columns` comme ``["phone"]`` et le `kms_key_arn` comme valeur de la variable d'environnement ``${KMS}``. La transformation chiffre les valeurs de la colonne « phone » à l'aide de la clé KMS spécifiée. Le `df_encrypt` qui en résulte DataFrame contient la colonne ``id`` d'origine, la colonne ``phone`` d'origine et une colonne supplémentaire nommée ``phone_encrypted`` contenant les valeurs cryptées de la colonne ``phone``.

Méthodes

- [__call__](#)
- [s'applique](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

```
__call__(spark_context, data_frame, source_columns, kms_key_arn, entity_type_filter=None,
preserve_data_type=None)
```

La Encrypt transformation chiffre les colonnes source à l'aide de la AWS clé du service de gestion des clés.

- `source_columns`— Un tableau de colonnes existantes.
- `kms_key_arn`— L'ARN AWS clé du service de gestion des clés à utiliser pour chiffrer les colonnes source.
- `entity_type_filter`— Tableau facultatif de types d'entités. Peut être utilisé pour chiffrer uniquement les informations personnelles détectées dans une colonne de texte libre.
- `preserve_data_type`— Booléen facultatif. La valeur par défaut est true (vrai). Si la valeur est fausse, le type de données ne sera pas enregistré.

```
apply(cls, *args, **kwargs)
```

Hérité de GlueTransform [s'appliquent](#).

```
name(cls)
```

Hérité de GlueTransform [name](#).

```
describeArgs(cls)
```

Hérité de GlueTransform [describeArgs](#).

```
describeReturn(cls)
```

Hérité de GlueTransform [describeReturn](#).

```
describeTransform(cls)
```

Hérité de GlueTransform [describeTransform](#).

```
describeErrors(cls)
```

Hérité de GlueTransform [describeErrors](#).

```
describe(cls)
```

Hérité de GlueTransform [describe](#).

IntToIp classe

La IntToIp transformation convertit la valeur entière de la colonne source ou d'une autre valeur en la IPv4 valeur correspondante dans la colonne cible puis renvoie le résultat dans une nouvelle colonne.

exemple

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsglue.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
    [
        (3221225473,),
        (0,),
        (1,),
        (100,),
        (168430090,),
        (4294967295,),
        (4294967294,),
        (4294967296,),
        (-1,),
        (None,)
    ],
    ["source_column_int"],
)

try:
    df_output = web_functions.IntToIp.apply(
        data_frame=input_df,
        spark_context=sc,
        source_column="source_column_int",
        target_column="target_column",
        value=None
    )
    df_output.show()
except:
    print("Unexpected Error happened ")
    raise
```

Sortie

Le résultat sera :

```

'''
+-----+-----+
|source_column_int|target_column|
+-----+-----+
3221225473	192.0.0.1
0	0.0.0.0
1	0.0.0.1
100	0.0.0.100
168430090	10.0.0.10
4294967295	255.255.255.255
4294967294	255.255.255.254
4294967296	null
-1	null
null	null
+-----+-----+
'''

```

La `IntToIp.apply` transformation prend la ``source_column`` comme ``"source_column_int"`` et la ``target_column`` comme ``"target_column"`` et convertit les valeurs entières de la colonne ``source_column_int`` en leur représentation d'adresse correspondante et stocke le résultat dans la colonne ``target_column``. IPv4

Pour les valeurs entières valides comprises dans la plage d' IPv4 adresses (0 à 4294967295), la transformation les convertit correctement en leur représentation d' IPv4 adresse (par exemple, 192.0.0.1, 0.0.0.0, 10.0.0.10, 255.255.255.255).

Pour les valeurs entières situées en dehors de la plage valide (par exemple, 4294967296, -1), la valeur ``target_column`` est définie sur ``null``. Pour les valeurs ``null`` de la colonne ``source_column_int``, la valeur ``target_column`` est également définie sur ``null``.

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)

- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

`__call__` (spark_context, data_frame, target_column, source_column=None, value=None)

La `IntToIp` transformation convertit la valeur entière de la colonne source ou d'une autre valeur en la IPv4 valeur correspondante dans la colonne cible puis renvoie le résultat dans une nouvelle colonne.

- `sourceColumn` : nom d'une colonne existante.
- `value`— Chaîne de caractères à évaluer.
- `targetColumn`— Nom de la nouvelle colonne à créer.

`apply(cls, *args, **kwargs)`

Hérité de `GlueTransform` [s'appliquent](#).

`name(cls)`

Hérité de `GlueTransform` [name](#).

`describeArgs(cls)`

Hérité de `GlueTransform` [describeArgs](#).

`describeReturn(cls)`

Hérité de `GlueTransform` [describeReturn](#).

`describeTransform(cls)`

Hérité de `GlueTransform` [describeTransform](#).

`describeErrors(cls)`

Hérité de `GlueTransform` [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

IpToInt classe

La IpToInt transformation convertit la valeur du protocole Internet version 4 (IPv4) de la colonne source ou une autre valeur en valeur entière correspondante dans la colonne cible, et renvoie le résultat dans une nouvelle colonne.

exemple

Pour AWS Glue 4.0 et versions ultérieures, créez ou mettez à jour les arguments de tâche avec key :
--enable-glue-di-transforms, value: true

```
from pyspark.context import SparkContext
from awsgluedi.transforms import *

sc = SparkContext()

input_df = spark.createDataFrame(
    [
        ("192.0.0.1",),
        ("10.10.10.10",),
        ("1.2.3.4",),
        ("1.2.3.6",),
        ("http://12.13.14.15",),
        ("https://16.17.18.19",),
        ("1.2.3.4",),
        (None,),
        ("abc",),
        ("abc.abc.abc.abc",),
        ("321.123.123.123",),
        ("244.4.4.4",),
        ("255.255.255.255",),
    ],
    ["source_column_ip"],
)

df_output = web_functions.IpToInt.apply(
    data_frame=input_df,
    spark_context=sc,
    source_column="source_column_ip",
```

```

        target_column="target_column",
        value=None
    )
    df_output.show()

```

Sortie

Le résultat sera :

```

...
+-----+-----+
|source_column_ip| target_column|
+-----+-----+
192.0.0.1	3221225473
10.10.10.10	168427722
1.2.3.4	16909060
1.2.3.6	16909062
http://12.13.14.15	null
https://16.17.18.19	null
1.2.3.4	16909060
null	null
abc	null
abc.abc.abc.abc	null
321.123.123.123	null
244.4.4.4	4102444804
255.255.255.255	4294967295
+-----+-----+
...

```

La `IpToInt` transformation prend la `source_column` comme `"source_column_ip"` et la `target_column` comme `"target_column"` et convertit les chaînes d'adresses valides de la colonne `source_column_ip` en leur représentation entière 32 bits correspondante et stocke le résultat dans la colonne `target_column`. IPv4

Pour les chaînes d'IPv4 adresses valides (par exemple, « 192.0.0.1 », « 10.10.10.10 », « 1.2.3.4 »), la transformation les convertit correctement en leur représentation entière (par exemple, 3221225473, 168427722, 16909060). Pour les chaînes qui ne sont pas des IPv4 adresses valides (par exemple URLs, les chaînes non IP comme « abc », les formats IP non valides tels que « abc.abc.abc.abc »), la valeur « target_column » est définie sur « null ». Pour les valeurs `null` de la colonne `source_column_ip`, la valeur `target_column` est également définie sur `null`.

Méthodes

- [__call__](#)
- [s'appliquent](#)
- [name](#)
- [describeArgs](#)
- [describeReturn](#)
- [describeTransform](#)
- [describeErrors](#)
- [describe](#)

`__call__` (spark_context, data_frame, target_column, source_column=None, value=None)

La IpToInt transformation convertit la valeur du protocole Internet version 4 (IPv4) de la colonne source ou une autre valeur en valeur entière correspondante dans la colonne cible, et renvoie le résultat dans une nouvelle colonne.

- `sourceColumn` : nom d'une colonne existante.
- `value`— Chaîne de caractères à évaluer.
- `targetColumn`— Nom de la nouvelle colonne à créer.

`apply(cls, *args, **kwargs)`

Hérité de GlueTransform [s'appliquent](#).

`name(cls)`

Hérité de GlueTransform [name](#).

`describeArgs(cls)`

Hérité de GlueTransform [describeArgs](#).

`describeReturn(cls)`

Hérité de GlueTransform [describeReturn](#).

describeTransform(cls)

Hérité de GlueTransform [describeTransform](#).

describeErrors(cls)

Hérité de GlueTransform [describeErrors](#).

describe(cls)

Hérité de GlueTransform [describe](#).

L'intégration des données transforme

Pour AWS Glue 4.0 et versions ultérieures, créez ou mettez à jour les arguments de tâche aveckey :
`--enable-glue-di-transforms, value: true`.

Exemple de script de tâche :

```
from pyspark.context import SparkContext

from awsgluedi.transforms import *
sc = SparkContext()

input_df = spark.createDataFrame(
    [(5,), (0,), (-1,), (2,), (None,)],
    ["source_column"],
)

try:
    df_output = math_functions.IsEven.apply(
        data_frame=input_df,
        spark_context=sc,
        source_column="source_column",
        target_column="target_column",
        value=None,
        true_string="Even",
        false_string="Not even",
    )
    df_output.show()
except:
    print("Unexpected Error happened ")
    raise
```

Exemples de sessions utilisant des blocs-notes

```
%idle_timeout 2880
%glue_version 4.0
%worker_type G.1X
%number_of_workers 5
%region eu-west-1
```

```
%%configure
{
    "--enable-glue-di-transforms": "true"
}
```

```
from pyspark.context import SparkContext
from awsgluedi.transforms import *

sc = SparkContext()

input_df = spark.createDataFrame(
    [(5,), (0,), (-1,), (2,), (None,)],
    ["source_column"],
)

try:
    df_output = math_functions.IsEven.apply(
        data_frame=input_df,
        spark_context=sc,
        source_column="source_column",
        target_column="target_column",
        value=None,
        true_string="Even",
        false_string="Not even",
    )
    df_output.show()
except:
    print("Unexpected Error happened ")
    raise
```

Exemples de sessions utilisant AWS CLI

```
aws glue create-session --default-arguments "--enable-glue-di-transforms=true"
```

DI transforme :

- [FlagDuplicatesInColumn classe](#)
- [FormatPhoneNumber classe](#)
- [FormatCase classe](#)
- [FillWithMode classe](#)
- [FlagDuplicateRows classe](#)
- [RemoveDuplicates classe](#)
- [MonthName classe](#)
- [IsEven classe](#)
- [CryptographicHash classe](#)
- [Classe de déchiffrement](#)
- [Classe de chiffrement](#)
- [IntToIp classe](#)
- [IpToInt classe](#)

Maven : associez le plugin à vos applications Spark

Vous pouvez associer la dépendance aux transformations à vos applications Spark et à vos distributions Spark (version 3.3) en ajoutant la dépendance au plugin dans votre Maven pom.xml tout en développant vos applications Spark localement.

```
<repositories>
  ...
  <repository>
    <id>aws-glue-etl-artifacts</id>
    <url>https://aws-glue-etl-artifacts.s3.amazonaws.com/release/ </url>
  </repository>
</repositories>
...
<dependency>
  <groupId>com.amazonaws</groupId>
  <artifactId>AWSGlueTransforms</artifactId>
  <version>4.0.0</version>
</dependency>
```

Vous pouvez également télécharger les fichiers binaires directement depuis les artefacts de AWS Glue Maven et les inclure dans votre application Spark comme suit.

```
#!/bin/bash
sudo wget -v https://aws-glue-etl-artifacts.s3.amazonaws.com/release/com/amazonaws/
AWSGlueTransforms/4.0.0/AWSGlueTransforms-4.0.0.jar -P /usr/lib/spark/jars/
```

Programmation AWS Glue Scripts ETL dans Scala

Vous pouvez trouver des exemples de code Scala et des utilitaires pour AWS Glue dans le [AWS Glue référentiel d'échantillons](#) sur le GitHub site Web.

AWS Glue prend en charge une extension du dialecte PySpark Scala pour les tâches d'extraction, de transformation et de chargement (ETL) par script. Les sections suivantes décrivent comment utiliser le AWS Glue La bibliothèque Scala et le AWS Glue API dans des scripts ETL, et fournissent une documentation de référence pour la bibliothèque.

Table des matières

- [Utiliser Scala pour programmer AWS Glue Scripts ETL](#)
 - [Test d'un programme ETL Scala dans un bloc-notes Jupyter sur un point de terminaison de développement](#)
 - [Test d'un programme ETL Scala dans un REPL Scala](#)
- [Exemple de script Scala — ETL de streaming](#)
- [APIs dans le AWS Glue Bibliothèque Scala](#)
 - [com.amazonaws.services.glue](#)
 - [com.amazonaws.services.glue.ml](#)
 - [com.amazonaws.services.glue.dq](#)
 - [com.amazonaws.services.glue.types](#)
 - [com.amazonaws.services.glue.util](#)
 - [AWS Glue Scala ChoiceOption APIs](#)
 - [ChoiceOption trait](#)
 - [ChoiceOption objet](#)
 - [def apply](#)
 - [Classe de cas ChoiceOptionWithResolver](#)
 - [Classe de cas MatchCatalogSchemaChoiceOption](#)

- [DataSink Classe abstraite](#)
 - [Déf writeDynamicFrame](#)
 - [pyWriteDynamicCadre Def](#)
 - [Déf writeDataFrame](#)
 - [pyWriteDataCadre Def](#)
 - [Déf setCatalogInfo](#)
 - [def supportsFormat](#)
 - [def setFormat](#)
 - [def withFormat](#)
 - [Déf setAccumulableSize](#)
 - [Déf getOutputError RecordsAccumulable](#)
 - [errorsAsDynamicCadre Def](#)
 - [DataSink objet](#)
 - [def recordMetrics](#)
- [AWS Glue Trait Scala DataSource](#)
- [AWS Glue Scala DynamicFrame APIs](#)
 - [AWS Glue Classe Scala DynamicFrame](#)
 - [val errorsCount](#)
 - [def applyMapping](#)
 - [Déf assertErrorThreshold](#)
 - [def count](#)
 - [def dropField](#)
 - [def dropFields](#)
 - [def dropNulls](#)
 - [errorsAsDynamicCadre Def](#)
 - [def filter](#)
 - [def getName](#)
 - [Déf getNumPartitions](#)
 - [Déf getSchemaIf calculé](#)
 - [Déf isSchemaComputed](#)

- [Déf javaToPython](#)
- [def join](#)
- [def map](#)
- [Déf mergeDynamicFrames](#)
- [def printSchema](#)
- [def recomputeSchema](#)
- [def relationalize](#)
- [def renameField](#)
- [def repartition](#)
- [def resolveChoice](#)
- [def schema](#)
- [def selectField](#)
- [def selectFields](#)
- [def show](#)
- [Définissez par simplifier DDBJson](#)
- [def spigot](#)
- [def splitFields](#)
- [def splitRows](#)
- [Déf stageErrorsCount](#)
- [def toDF](#)
- [def unbox](#)
- [def unnest](#)
- [Def Unnest DDBJson](#)
- [Déf withFrameSchema](#)
- [def withName](#)
- [Déf withTransformationContext](#)
- [L' DynamicFrame objet](#)
 - [def apply](#)
 - [Déf emptyDynamicFrame](#)
 - [def fromPythonRDD](#)

- [def ignoreErrors](#)
- [def inlineErrors](#)
- [newFrameWithErreurs de définition](#)
- [AWS Glue Classe Scala DynamicRecord](#)
 - [def addField](#)
 - [def dropField](#)
 - [def setError](#)
 - [def isError](#)
 - [def getError](#)
 - [def clearError](#)
 - [def write](#)
 - [def readFields](#)
 - [def clone](#)
 - [def schema](#)
 - [def getRoot](#)
 - [def toJson](#)
 - [Déf getFieldNode](#)
 - [def getField](#)
 - [def hashCode](#)
 - [def equals](#)
 - [DynamicRecord objet](#)
 - [Def apply](#)
 - [RecordTraverser trait](#)
- [AWS Glue Scala GlueContext APIs](#)
 - [addIngestionTimeColonnes def](#)
 - [def createDataFrame FromOptions](#)
 - [forEachBatch](#)
 - [def getCatalogSink](#)
 - [def getCatalogSource](#)
 - [def get JDBC Sink](#)

- [def getSink](#)
- [getSinkWithFormat def](#)
- [def getSource](#)
- [getSourceWithFormat def](#)
- [def getSparkSession](#)
- [def startTransaction](#)
- [def commitTransaction](#)
- [def cancelTransaction](#)
- [def this](#)
- [def this](#)
- [def this](#)
- [MappingSpec](#)
 - [MappingSpec classe de cas](#)
 - [MappingSpec objet](#)
 - [Val orderingByTarget](#)
 - [Def apply](#)
 - [def apply](#)
 - [Def apply](#)
- [AWS Glue Scala ResolveSpec APIs](#)
 - [ResolveSpec objet](#)
 - [def](#)
 - [def](#)
 - [ResolveSpec classe de cas](#)
 - [ResolveSpec méthodes def](#)
- [AWS Glue Scala ArrayNode APIs](#)
 - [ArrayNode classe de cas](#)
 - [ArrayNode méthodes def](#)
- [AWS Glue Scala BinaryNode APIs](#)
 - [BinaryNode classe de cas](#)
 - [BinaryNode champs de val](#)

- [BinaryNode méthodes def](#)
- [AWS Glue Scala BooleanNode APIs](#)
 - [BooleanNode classe de cas](#)
 - [BooleanNode champs de val](#)
 - [BooleanNode méthodes def](#)
- [AWS Glue Scala ByteNode APIs](#)
 - [ByteNode classe de cas](#)
 - [ByteNode champs de val](#)
 - [ByteNode méthodes def](#)
- [AWS Glue Scala DateNode APIs](#)
 - [DateNode classe de cas](#)
 - [DateNode champs de val](#)
 - [DateNode méthodes def](#)
- [AWS Glue Scala DecimalNode APIs](#)
 - [DecimalNode classe de cas](#)
 - [DecimalNode champs de val](#)
 - [DecimalNode méthodes def](#)
- [AWS Glue Scala DoubleNode APIs](#)
 - [DoubleNode classe de cas](#)
 - [DoubleNode champs de val](#)
 - [DoubleNode méthodes def](#)
- [AWS Glue Scala DynamicNode APIs](#)
 - [DynamicNode classe](#)
 - [DynamicNode méthodes def](#)
 - [DynamicNode objet](#)
 - [DynamicNode méthodes def](#)
- [EvaluateDataQuality classe](#)
 - [Def apply](#)
 - [exemple](#)
- [AWS Glue Scala FloatNode APIs](#)

- [FloatNode classe de cas](#)
 - [FloatNode champs de val](#)
 - [FloatNode méthodes def](#)
- [FillMissingValues classe](#)
 - [def apply](#)
- [FindMatches classe](#)
 - [def apply](#)
- [FindIncrementalMatches classe](#)
 - [def apply](#)
- [AWS Glue Scala IntegerNode APIs](#)
 - [IntegerNode classe de cas](#)
 - [IntegerNode champs de val](#)
 - [IntegerNode méthodes def](#)
- [AWS Glue Scala LongNode APIs](#)
 - [LongNode classe de cas](#)
 - [LongNode champs de val](#)
 - [LongNode méthodes def](#)
- [AWS Glue Scala MapLikeNode APIs](#)
 - [MapLikeNode classe](#)
 - [MapLikeNode méthodes def](#)
- [AWS Glue Scala MapNode APIs](#)
 - [MapNode classe de cas](#)
 - [MapNode méthodes def](#)
- [AWS Glue Scala NullNode APIs](#)
 - [NullNode classe](#)
 - [NullNode objet du boîtier](#)
- [AWS Glue Scala ObjectNode APIs](#)
 - [ObjectNode objet](#)
 - [ObjectNode méthodes def](#)
 - [ObjectNode classe de cas](#)

- [ObjectNode méthodes def](#)
- [AWS Glue Scala ScalarNode APIs](#)
 - [ScalarNode classe](#)
 - [ScalarNode méthodes def](#)
 - [ScalarNode objet](#)
 - [ScalarNode méthodes def](#)
- [AWS Glue Scala ShortNode APIs](#)
 - [ShortNode classe de cas](#)
 - [ShortNode champs de val](#)
 - [ShortNode méthodes def](#)
- [AWS Glue Scala StringNode APIs](#)
 - [StringNode classe de cas](#)
 - [StringNode champs de val](#)
 - [StringNode méthodes def](#)
- [AWS Glue Scala TimestampNode APIs](#)
 - [TimestampNode classe de cas](#)
 - [TimestampNode champs de val](#)
 - [TimestampNode méthodes def](#)
- [AWS Glue Scala GlueArgParser APIs](#)
 - [Objet GlueArgParser](#)
 - [GlueArgParser méthodes def](#)
- [AWS Glue Job Scala APIs](#)
 - [Objet Job](#)
 - [Modes def Job](#)

Utiliser Scala pour programmer AWS Glue Scripts ETL

Vous pouvez générer automatiquement un programme d'extraction, de transformation et de chargement (ETL) Scala à l'aide du AWS Glue console, et modifiez-la selon vos besoins avant de l'affecter à une tâche. Vous pouvez également écrire votre propre programme à partir de zéro. Pour

de plus amples informations, veuillez consulter [Configuration des propriétés des tâches pour les](#)

[tâches Spark dans AWS Glue](#). AWS Glue compile ensuite votre programme Scala sur le serveur avant d'exécuter le travail associé.

Pour vous assurer que votre programme se compile sans erreur et s'exécute comme prévu, il est important de le charger sur un terminal de développement dans un REPL (Read-Eval-Print Loop) ou un bloc-notes Jupyter et de le tester là avant de l'exécuter dans un job. Étant donné que le processus de compilation intervient sur le serveur, vous n'aurez pas une bonne visibilité sur les éventuels problèmes qui s'y produisent.

Test d'un programme ETL Scala dans un bloc-notes Jupyter sur un point de terminaison de développement

Pour tester un programme Scala sur un AWS Glue point de terminaison de développement, configurez le point de terminaison de développement comme décrit dans [Ajout d'un point de terminaison de développement](#).

Ensuite, connectez-le à un bloc-notes Jupyter qui s'exécute localement sur votre machine ou à distance sur un serveur de EC2 bloc-notes Amazon. Pour installer une version locale d'un bloc-notes Jupyter, suivez les instructions fournies dans [Tutoriel : bloc-notes Jupyter dans JupyterLab](#).

La seule différence entre exécuter du code Scala et exécuter PySpark du code sur votre bloc-notes est que vous devez commencer chaque paragraphe du bloc-notes avec ce qui suit :

```
%spark
```

Cela empêche le serveur Notebook d'utiliser par défaut la version de l' PySparkinterpréteur Spark.

Test d'un programme ETL Scala dans un REPL Scala

Vous pouvez tester un programme Scala sur un terminal de développement à l'aide du AWS GlueÉchelle REPL. Suivez les instructions indiquées dans [Tutoriel : Utiliser un bloc-notes SageMaker AI](#), sauf à la fin de la SSH-to-REPL commande, remplacez `-t gluepyspark` par `-t glue-spark-shell`. Cela invoque le AWS Glue Échelle REPL.

Pour fermer la fonction REPL lorsque vous avez terminé, tapez `sys.exit`.

Exemple de script Scala — ETL de streaming

Exemple

L'exemple de script ci-dessous se connecte à Amazon Kinesis Data Streams, utilise un schéma à partir du Data Catalog pour analyser un flux de données, joint le flux à un jeu de données statique sur Amazon S3 et génère les résultats joints dans Amazon S3 au format Parquet.

```
// This script connects to an Amazon Kinesis stream, uses a schema from the data
// catalog to parse the stream,
// joins the stream to a static dataset on Amazon S3, and outputs the joined results to
// Amazon S3 in parquet format.
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import java.util.Calendar
import org.apache.spark.SparkContext
import org.apache.spark.sql.Dataset
import org.apache.spark.sql.Row
import org.apache.spark.sql.SaveMode
import org.apache.spark.sql.SparkSession
import org.apache.spark.sql.functions.from_json
import org.apache.spark.sql.streaming.Trigger
import scala.collection.JavaConverters._

object streamJoiner {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val sparkSession: SparkSession = glueContext.getSparkSession
    import sparkSession.implicits._
    // @params: [JOB_NAME]
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    val staticData = sparkSession.read          // read() returns type DataFrameReader
      .format("csv")
      .option("header", "true")
      .load("s3://amzn-s3-demo-bucket/inputs/productsStatic.csv") // load() returns a
    DataFrame

    val datasource0 = sparkSession.readStream  // readstream() returns type
    DataStreamReader
```



```

    .format("kinesis")
    .option("streamName", "stream-join-demo")
    .option("endpointUrl", "https://kinesis.us-east-1.amazonaws.com")
    .option("startingPosition", "TRIM_HORIZON")
    .load // load() returns a DataFrame

    val selectfields1 = datasource0.select(from_json($"data".cast("string"),
glueContext.getCatalogSchemaAsSparkSchema("stream-demos", "stream-join-demo2")) as
"data").select("data.*")

    val datasink2 = selectfields1.writeStream.foreachBatch { (dataFrame: Dataset[Row],
batchId: Long) => { //foreachBatch() returns type DataStreamWriter
        val joined = dataFrame.join(staticData, "product_id")
        val year: Int = Calendar.getInstance().get(Calendar.YEAR)
        val month :Int = Calendar.getInstance().get(Calendar.MONTH) + 1
        val day: Int = Calendar.getInstance().get(Calendar.DATE)
        val hour: Int = Calendar.getInstance().get(Calendar.HOUR_OF_DAY)

        if (dataFrame.count() > 0) {
            joined.write // joined.write returns type
DataFrameWriter
                .mode(SaveMode.Append)
                .format("parquet")
                .option("quote", " ")
                .save("s3://amzn-s3-demo-bucket/output/" + "/year=" + "%04d".format(year)
+ "/month=" + "%02d".format(month) + "/day=" + "%02d".format(day) + "/hour=" +
"%02d".format(hour) + "/" )
        }
    } // end foreachBatch()
    .trigger(Trigger.ProcessingTime("100 seconds"))
    .option("checkpointLocation", "s3://amzn-s3-demo-bucket/checkpoint/")
    .start().awaitTermination() // start() returns type StreamingQuery
    Job.commit()
}
}

```

APIs dans le AWS Glue Bibliothèque Scala

AWS Glue prend en charge une extension du dialecte PySpark Scala pour les tâches d'extraction, de transformation et de chargement (ETL) de scripts. Les sections suivantes décrivent APIs le AWS Glue Bibliothèque Scala.

com.amazonaws.services.glue

Le package com.amazonaws.services.glue dans le AWS Glue La bibliothèque Scala contient les éléments suivants : APIs

- [ChoiceOption](#)
- [DataSink](#)
- [DataSource trait](#)
- [DynamicFrame](#)
- [DynamicRecord](#)
- [GlueContext](#)
- [MappingSpec](#)
- [ResolveSpec](#)

com.amazonaws.services.glue.ml

Le package com.amazonaws.services.glue.ml dans AWS Glue La bibliothèque Scala contient les éléments suivants : APIs

- [FillMissingValues](#)
- [FindIncrementalMatches](#)
- [FindMatches](#)

com.amazonaws.services.glue.dq

Le package com.amazonaws.services.glue.dq dans AWS Glue La bibliothèque Scala contient les éléments suivants : APIs

- [EvaluateDataQuality](#)

com.amazonaws.services.glue.types

Le package com.amazonaws.services.glue.types dans le AWS Glue La bibliothèque Scala contient les éléments suivants : APIs

- [ArrayNode](#)
- [BinaryNode](#)

- [BooleanNode](#)
- [ByteNode](#)
- [DateNode](#)
- [DecimalNode](#)
- [DoubleNode](#)
- [DynamicNode](#)
- [FloatNode](#)
- [IntegerNode](#)
- [LongNode](#)
- [MapLikeNode](#)
- [MapNode](#)
- [NullNode](#)
- [ObjectNode](#)
- [ScalarNode](#)
- [ShortNode](#)
- [StringNode](#)
- [TimestampNode](#)

com.amazonaws.services.glue.util

Le package com.amazonaws.services.glue.util dans AWS Glue La bibliothèque Scala contient les éléments suivants : APIs

- [GlueArgParser](#)
- [Tâche](#)

AWS Glue Scala ChoiceOption APIs

Rubriques

- [ChoiceOption trait](#)
- [ChoiceOption objet](#)
- [Classe de cas ChoiceOptionWithResolver](#)
- [Classe de cas MatchCatalogSchemaChoiceOption](#)

Package : com.amazonaws.services.glue

ChoiceOption trait

```
trait ChoiceOption extends Serializable
```

ChoiceOption objet

ChoiceOption

```
object ChoiceOption
```

Une stratégie générale pour résoudre les choix applicables à tous les nœuds ChoiceType d'un DynamicFrame.

- val CAST
- val MAKE_COLS
- val MAKE_STRUCT
- val MATCH_CATALOG
- val PROJECT

def apply

```
def apply(choice: String): ChoiceOption
```

Classe de cas ChoiceOptionWithResolver

```
case class ChoiceOptionWithResolver(name: String, choiceResolver: ChoiceResolver)  
  extends ChoiceOption {}
```

Classe de cas MatchCatalogSchemaChoiceOption

```
case class MatchCatalogSchemaChoiceOption() extends ChoiceOption {}
```

DataSink Classe abstraite

Rubriques

- [Déf writeDynamicFrame](#)
- [pyWriteDynamicCadre Def](#)
- [Déf writeDataFrame](#)
- [pyWriteDataCadre Def](#)
- [Déf setCatalogInfo](#)
- [def supportsFormat](#)
- [def setFormat](#)
- [def withFormat](#)
- [Déf setAccumulableSize](#)
- [Déf getOutputError RecordsAccumulable](#)
- [errorsAsDynamicCadre Def](#)
- [DataSink objet](#)

Package : com.amazonaws.services.glue

```
abstract class DataSink
```

L'enregistreur analogue à un encapsule un DataSource. DataSink encapsule une destination et un format dans lequel un DynamicFrame peut être écrit.

Déf writeDynamicFrame

```
def writeDynamicFrame( frame : DynamicFrame,  
                      callSite : CallSite = CallSite("Not provided", "")  
                      ) : DynamicFrame
```

pyWriteDynamicCadre Def

```
def pyWriteDynamicFrame( frame : DynamicFrame,  
                        site : String = "Not provided",  
                        info : String = "" )
```

Déf writeDataFrame

```
def writeDataFrame(frame: DataFrame,
```

```
glueContext: GlueContext,  
callSite: CallSite = CallSite("Not provided", "")  
): DataFrame
```

pyWriteDataCadre Def

```
def pyWriteDataFrame(frame: DataFrame,  
    glueContext: GlueContext,  
    site: String = "Not provided",  
    info: String = ""  
): DataFrame
```

Déf setCatalogInfo

```
def setCatalogInfo(catalogDatabase: String,  
    catalogTableName : String,  
    catalogId : String = "")
```

def supportsFormat

```
def supportsFormat( format : String ) : Boolean
```

def setFormat

```
def setFormat( format : String,  
    options : JsonOptions  
    ) : Unit
```

def withFormat

```
def withFormat( format : String,  
    options : JsonOptions = JsonOptions.empty  
    ) : DataSink
```

Déf setAccumulableSize

```
def setAccumulableSize( size : Int ) : Unit
```

Déf getOutputError RecordsAccumulable

```
def getOutputErrorRecordsAccumulable : Accumulable[List[OutputError], OutputError]
```

errorsAsDynamicCadre Def

```
def errorsAsDynamicFrame : DynamicFrame
```

DataSink objet

```
object DataSink
```

def recordMetrics

```
def recordMetrics( frame : DynamicFrame,
                  ctxt : String
                  ) : DynamicFrame
```

AWS Glue Trait Scala DataSource

Package : com.amazonaws.services.glue

Interface de haut niveau pour produire un DynamicFrame.

```
trait DataSource {

  def getDynamicFrame : DynamicFrame

  def getDynamicFrame( minPartitions : Int,
                      targetPartitions : Int
                      ) : DynamicFrame

  def getDataFrame : DataFrame

  /** @param num: the number of records for sampling.
    * @param options: optional parameters to control sampling behavior. Current
    available parameter for Amazon S3 sources in options:
    * 1. maxSamplePartitions: the maximum number of partitions the sampling will
    read.
```

```
* 2. maxSampleFilesPerPartition: the maximum number of files the sampling will
read in one partition.
*/
def getSampleDynamicFrame(num:Int, options: JsonOptions = JsonOptions.empty):
DynamicFrame

def glueContext : GlueContext

def setFormat( format : String,
               options : String
               ) : Unit

def setFormat( format : String,
               options : JsonOptions
               ) : Unit

def supportsFormat( format : String ) : Boolean

def withFormat( format : String,
                options : JsonOptions = JsonOptions.empty
                ) : DataSource
}
```

AWS Glue Scala DynamicFrame APIs

Package : `com.amazonaws.services.glue`

Table des matières

- [AWS Glue Classe Scala DynamicFrame](#)
 - [val errorsCount](#)
 - [def applyMapping](#)
 - [Déf assertErrorThreshold](#)
 - [def count](#)
 - [def dropField](#)
 - [def dropFields](#)
 - [def dropNulls](#)
 - [errorsAsDynamicCadre Def](#)
 - [def filter](#)
 - [def getName](#)

- [Déf getNumPartitions](#)
 - [Déf getSchemaIf calculé](#)
 - [Déf isSchemaComputed](#)
 - [Déf javaToPython](#)
 - [def join](#)
 - [def map](#)
 - [Déf mergeDynamicFrames](#)
 - [def printSchema](#)
 - [def recomputeSchema](#)
 - [def relationalize](#)
 - [def renameField](#)
 - [def repartition](#)
 - [def resolveChoice](#)
 - [def schema](#)
 - [def selectField](#)
 - [def selectFields](#)
 - [def show](#)
 - [Définissez par simplifier DDBJson](#)
 - [def spigot](#)
 - [def splitFields](#)
 - [def splitRows](#)
 - [Déf stageErrorsCount](#)
 - [def toDF](#)
 - [def unbox](#)
 - [def unnest](#)
 - [Def Unnest DDBJson](#)
 - [Déf withFrameSchema](#)
 - [def withName](#)
 - [Déf withTransformationContext](#)
-
- [L' DynamicFrame objet](#)

- [def apply](#)
- [Déf emptyDynamicFrame](#)
- [def fromPythonRDD](#)
- [def ignoreErrors](#)
- [def inlineErrors](#)
- [newFrameWithErreurs de définition](#)

AWS Glue Classe Scala DynamicFrame

Package : com.amazonaws.services.glue

```
class DynamicFrame extends Serializable with Logging {  
    val glueContext : GlueContext,  
    _records : RDD[DynamicRecord],  
    val name : String = s"",  
    val transformationContext : String = DynamicFrame.UNDEFINED,  
    callSite : CallSite = CallSite("Not provided", ""),  
    stageThreshold : Long = 0,  
    totalThreshold : Long = 0,  
    prevErrors : => Long = 0,  
    errorExpr : => Unit = {} )
```

Un `DynamicFrame` est une collection distribuée d'objets [DynamicRecord](#) à description automatique.

Le `DynamicFrame` est conçu pour fournir un modèle de données flexible pour les opérations ETL (extraction, transformation et chargement). Il ne nécessite pas de créer un schéma et peut être utilisé pour lire et transformer les données contenant des valeurs et des types incohérents ou complexes. Un schéma peut être calculé à la demande pour les opérations qui en nécessitent un.

Les `DynamicFrame` fournissent une plage de transformations pour le nettoyage des données et ETL. Ils prennent également en charge la conversion vers et depuis `DataFrames SparkSQL` afin de s'intégrer au code existant et aux nombreuses opérations d'analyse qui en découlent. `DataFrames`

Les paramètres suivants sont partagés par de nombreux AWS Glue transformations qui construisent `DynamicFrame` s :

- `transformationContext` – Identificateur pour ce `DynamicFrame`. Le `transformationContext` est utilisé en tant que clé pour l'état de marque-page de tâche conservé d'une exécution à l'autre.

- `callSite` — fournit les informations de contexte pour le signalement d'erreurs. Ces valeurs sont automatiquement définies lors de l'appel à partir de Python.
- `stageThreshold` — Nombre maximal d'enregistrements d'erreurs autorisés depuis le calcul du `DynamicFrame` avant de lever une exception, à l'exclusion des enregistrements présents dans le `DynamicFrame` précédent.
- `totalThreshold` — Nombre maximal d'enregistrements d'erreur avant qu'une exception ne soit levée, y compris ceux des images précédentes.

`val errorsCount`

```
val errorsCount
```

Nombre d'enregistrements d'erreur dans le `DynamicFrame`. Les erreurs des opérations précédentes sont incluses dans le nombre.

`def applyMapping`

```
def applyMapping( mappings : Seq[Product4[String, String, String, String]],
                  caseSensitive : Boolean = true,
                  transformationContext : String = "",
                  callSite : CallSite = CallSite("Not provided", ""),
                  stageThreshold : Long = 0,
                  totalThreshold : Long = 0
                ) : DynamicFrame
```

- `mappings` – Séquence des mappages pour construire un nouveau `DynamicFrame`.
- `caseSensitive` — indique si les colonnes sources sont considérées comme sensibles à la casse. La définition de ce paramètre sur `false` peut s'avérer utile lors de l'intégration à des boutiques qui ne distinguent pas les majuscules des minuscules, comme le AWS Glue Data Catalog.

Sélectionne, projette et convertit les colonnes en fonction d'une séquence de mappages.

Chaque mappage se compose d'une colonne source et d'un type, ainsi que d'une colonne cible et d'un type. Les mappages peuvent être spécifiés sous forme de quatre tuples (`source_path`, `source_type`, `target_path`, `target_type`) ou d'un objet [MappingSpec](#) contenant les mêmes informations.

En plus des projections simples et de la conversion, les mappages peuvent être utilisés pour imbriquer ou désimbriquer les champs en séparant les composants du chemin d'accès par « . » (point).

Par exemple, supposons que vous ayez une trame `DynamicFrame` avec le schéma suivant.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address: struct
  |     |-- state: string
  |     |-- zip: int
  }}}}
```

Vous pouvez effectuer l'appel suivant pour désimbriquer les champs `state` et `zip`.

```
{{{
  df.applyMapping(
    Seq(("name", "string", "name", "string"),
        ("age", "int", "age", "int"),
        ("address.state", "string", "state", "string"),
        ("address.zip", "int", "zip", "int")))
  }}}}
```

Le schéma obtenu est le suivant.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- state: string
  |-- zip: int
  }}}}
```

Vous pouvez également utiliser `applyMapping` pour réimbriquer les colonnes. Par exemple, ce qui suit inverse la transformation précédente et crée une structure nommée `address` dans la cible.

```
{{{
  df.applyMapping(
    Seq(("name", "string", "name", "string"),
        ("age", "int", "age", "int"),
```

```
    ("state", "string", "address.state", "string"),
    ("zip", "int", "address.zip", "int")))
  }}}
```

Les noms de champ qui contiennent des caractères « . » (point) peuvent être placés entre guillemets (` `).

Note

La méthode `applyMapping` ne peut pas être utilisée actuellement pour mapper les colonnes imbriquées sous des tableaux.

Déf `assertErrorThreshold`

```
def assertErrorThreshold : Unit
```

Action qui oblige le calcul et vérifie que le nombre d'enregistrements d'erreur est inférieur à `stageThreshold` et `totalThreshold`. Lève une exception si l'une ou l'autre condition échoue.

def `count`

```
lazy
def count
```

Retourne le nombre d'éléments dans le `DynamicFrame`.

def `dropField`

```
def dropField( path : String,
               transformationContext : String = "",
               callSite : CallSite = CallSite("Not provided", ""),
               stageThreshold : Long = 0,
               totalThreshold : Long = 0
             ) : DynamicFrame
```

Renvoie un nouveau `DynamicFrame` avec la colonne spécifiée supprimée.

def `dropFields`

```
def dropFields( fieldNames : Seq[String],    // The column names to drop.
```

```

        transformationContext : String = "",
        callSite : CallSite = CallSite("Not provided", ""),
        stageThreshold : Long = 0,
        totalThreshold : Long = 0
    ) : DynamicFrame

```

Renvoie un nouveau `DynamicFrame` avec les colonnes spécifiées supprimées.

Vous pouvez utiliser cette méthode pour supprimer les colonnes imbriquées, y compris celles à l'intérieur de tableaux, mais pas pour supprimer des éléments de tableau spécifiques.

def dropNulls

```

def dropNulls( transformationContext : String = "",
               callSite : CallSite = CallSite("Not provided", ""),
               stageThreshold : Long = 0,
               totalThreshold : Long = 0 )

```

Renvoie un nouveau `DynamicFrame` avec toutes les colonnes null supprimées.

Note

Seules les colonnes de type `NullType` sont supprimées. Les valeurs null des autres colonnes ne sont pas supprimées ou modifiées.

errorsAsDynamicFrame Def

```
def errorsAsDynamicFrame
```

Renvoie un nouveau `DynamicFrame` contenant les enregistrements d'erreur de ce `DynamicFrame`.

def filter

```

def filter( f : DynamicRecord => Boolean,
            errorMsg : String = "",
            transformationContext : String = "",
            callSite : CallSite = CallSite("Not provided"),
            stageThreshold : Long = 0,
            totalThreshold : Long = 0

```

```
) : DynamicFrame
```

Crée un nouveau `DynamicFrame` contenant uniquement les enregistrements pour lesquels la fonction 'f' renvoie la valeur `true`. La fonction de filtre 'f' ne doit pas muter l'enregistrement d'entrée.

def getName

```
def getName : String
```

Renvoie le nom du `DynamicFrame`.

Déf getNumPartitions

```
def getNumPartitions
```

Retourne le nombre de partitions du `DynamicFrame`.

Déf getSchemaIf calculé

```
def getSchemaIfComputed : Option[Schema]
```

Renvoie le schéma s'il a déjà été calculé. N'analyse pas les données si le schéma n'a pas déjà été calculé.

Déf isSchemaComputed

```
def isSchemaComputed : Boolean
```

Renvoie la valeur `true` si le schéma a été calculé pour ce `DynamicFrame`, ou `false` dans le cas contraire. Si la méthode renvoie la valeur `false`, l'appel de la méthode `schema` nécessite un autre passage sur les enregistrements du `DynamicFrame`.

Déf javaToPython

```
def javaToPython : JavaRDD[Array[Byte]]
```

def join

```
def join( keys1 : Seq[String],
```

```
keys2 : Seq[String],  
frame2 : DynamicFrame,  
transformationContext : String = "",  
callSite : CallSite = CallSite("Not provided", ""),  
stageThreshold : Long = 0,  
totalThreshold : Long = 0  
) : DynamicFrame
```

- `keys1` — Colonnes de ce `DynamicFrame` à utiliser pour la jointure.
- `keys2` — colonnes de `frame2` à utiliser pour la jointure. Doit être de la même longueur que `keys1`.
- `frame2` — Autre `DynamicFrame` à joindre.

Renvoie le résultat de l'exécution d'une équijointure avec `frame2` à l'aide des clés spécifiées.

def map

```
def map( f : DynamicRecord => DynamicRecord,  
        errorMsg : String = "",  
        transformationContext : String = "",  
        callSite : CallSite = CallSite("Not provided", ""),  
        stageThreshold : Long = 0,  
        totalThreshold : Long = 0  
        ) : DynamicFrame
```

Renvoie un nouveau `DynamicFrame` construit en appliquant la fonction spécifiée 'f' à chaque enregistrement du `DynamicFrame`.

Comme cette méthode copie chaque enregistrement avant d'appliquer la fonction spécifiée, elle est sécurisée pour muter les enregistrements. Si la fonction de mappage lève une exception sur un enregistrement donné, celui-ci est marqué comme erreur, et le suivi de la pile est enregistré en tant que colonne dans l'enregistrement d'erreur.

Déf `mergeDynamicFrames`

```
def mergeDynamicFrames( stageDynamicFrame: DynamicFrame, primaryKeys: Seq[String],  
                        transformationContext: String = "",  
                        options: JsonOptions = JsonOptions.empty, callSite: CallSite =  
                        CallSite("Not provided"),
```



```
stageThreshold: Long = 0, totalThreshold: Long = 0):
```

DynamicFrame

- `stageDynamicFrame` — trame `DynamicFrame` intermédiaire à fusionner.
- `primaryKeys` — liste des champs de clé primaire permettant de faire correspondre les enregistrements des trames `DynamicFrame` source et intermédiaire.
- `transformationContext` — chaîne unique utilisée pour récupérer les métadonnées relatives à la transformation en cours (facultatif).
- `options` — chaîne de paires nom-valeur JSON qui fournissent des informations supplémentaires pour cette transformation.
- `callSite` — permet de fournir des informations contextuelles pour le signalement d'erreurs.
- `stageThreshold` – Une `Long`. Nombre d'erreurs identifiées dans la transformation donnée et à corriger lors du traitement.
- `totalThreshold` – Une `Long`. Nombre total d'erreurs identifiées dans la transformation donnée et qui doivent être corrigées lors du traitement.

Fusionne cette trame `DynamicFrame` avec une trame `DynamicFrame` intermédiaire basée sur les clés primaires spécifiées pour identifier les enregistrements. Les registres en double (registres avec les mêmes clés primaires) ne sont pas dédupliqués. Si aucun enregistrement ne correspond dans la trame intermédiaire, tous les enregistrements (y compris les doublons) sont conservés dans la source. Si la trame intermédiaire contient des enregistrements correspondants, les enregistrements de la trame intermédiaire remplacent les enregistrements de la source dans AWS Glue.

La trame `DynamicFrame` renvoyée contient l'enregistrement A dans les cas suivants :

1. Si A se trouve à la fois dans la trame source et la trame intermédiaire, c'est la valeur A de la trame intermédiaire qui est renvoyée.
2. Si A se trouve dans la table source et si `A.primaryKeys` ne se trouve pas dans la trame `stagingDynamicFrame` (en d'autres termes, A n'est pas mis à jour dans la table intermédiaire).

La trame source et la trame intermédiaire n'ont pas besoin d'avoir le même schéma.

Exemple

```
val mergedFrame: DynamicFrame = srcFrame.mergeDynamicFrames(stageFrame, Seq("id1", "id2"))
```

def printSchema

```
def printSchema : Unit
```

Imprime le schéma du `DynamicFrame` sur `stdout` dans un format compréhensible par les utilisateurs.

def recomputeSchema

```
def recomputeSchema : Schema
```

Force le recalcul d'un schéma. Ceci nécessite une analyse des données, mais peut « resserrer » le schéma si certains champs du schéma actuel ne sont pas présents dans les données.

Renvoie le schéma recalculé.

def relationalize

```
def relationalize( rootTableName : String,
                  stagingPath : String,
                  options : JsonOptions = JsonOptions.empty,
                  transformationContext : String = "",
                  callSite : CallSite = CallSite("Not provided"),
                  stageThreshold : Long = 0,
                  totalThreshold : Long = 0
                ) : Seq[DynamicFrame]
```

- `rootTableName` — nom à utiliser pour le `DynamicFrame` de base dans la sortie. Les trames `DynamicFrame` qui sont créés par les tableaux pivotants commencent avec ce préfixe.
- `stagingPath` — chemin Amazon Simple Storage Service (Amazon S3) pour écrire des données intermédiaires.
- `options` — crée les relations entre les options et la configuration. Non utilisé actuellement.

Aplanit toutes les structures imbriquées et pivote les tableaux en tables distinctes.

Vous pouvez utiliser cette opération pour préparer les données profondément imbriquées en vue de leur ingestion dans une base de données relationnelle. Les structs imbriquées sont mises à plat de la même manière que la transformation [unnest](#). De plus, les tableaux sont pivotés en tables distinctes

et chaque élément du tableau devient une ligne. Par exemple, supposons que vous ayez une trame `DynamicFrame` avec les données suivantes.

```
{"name": "Nancy", "age": 47, "friends": ["Fred", "Lakshmi"]}
{"name": "Stephanie", "age": 28, "friends": ["Yao", "Phil", "Alvin"]}
{"name": "Nathan", "age": 54, "friends": ["Nicolai", "Karen"]}
```

Exécutez le code suivant.

```
{{{
  df.relationalize("people", "s3:/my_bucket/my_path", JsonOptions.empty)
}}}
```

Il génère deux tables. La première table est nommée « people » et contient les éléments suivants.

```
{{{
  {"name": "Nancy", "age": 47, "friends": 1}
  {"name": "Stephanie", "age": 28, "friends": 2}
  {"name": "Nathan", "age": 54, "friends": 3}
}}}
```

Ici, le tableau « friends » a été remplacé par une clé de jointure générée automatiquement. Une table séparée nommée `people.friends` est créée avec le contenu suivant.

```
{{{
  {"id": 1, "index": 0, "val": "Fred"}
  {"id": 1, "index": 1, "val": "Lakshmi"}
  {"id": 2, "index": 0, "val": "Yao"}
  {"id": 2, "index": 1, "val": "Phil"}
  {"id": 2, "index": 2, "val": "Alvin"}
  {"id": 3, "index": 0, "val": "Nicolai"}
  {"id": 3, "index": 1, "val": "Karen"}
}}}
```

Dans ce tableau, « id » est une clé de jointure qui identifie de quel enregistrement provenait l'élément de tableau, « index » fait référence à la position dans le tableau d'origine et « val » est l'entrée réelle du tableau.

La méthode `relationalize` renvoie la séquence de `DynamicFrame` créée en appliquant ce processus de façon récursive à tous les tableaux.

 Note

Le AWS Glue la bibliothèque génère automatiquement des clés de jointure pour les nouvelles tables. Pour vous assurer que les clés de jointure sont uniques au travers des exécutions de tâche, vous devez activer les marque-pages de tâche.

def renameField

```
def renameField( oldName : String,
                 newName : String,
                 transformationContext : String = "",
                 callSite : CallSite = CallSite("Not provided", ""),
                 stageThreshold : Long = 0,
                 totalThreshold : Long = 0
               ) : DynamicFrame
```

- `oldName` — Nom d'origine de la colonne.
- `newName` — Nouveau nom de la colonne.

Renvoie un nouveau `DynamicFrame` contenant le champ spécifié renommé.

Cette méthode peut être utilisée pour renommer les champs imbriqués. Par exemple, le code suivant remplace le nom `state` par `state_code` dans la structure de l'adresse.

```
{{{
  df.renameField("address.state", "address.state_code")
}}}
```

def repartition

```
def repartition( numPartitions : Int,
                 transformationContext : String = "",
                 callSite : CallSite = CallSite("Not provided", ""),
                 stageThreshold : Long = 0,
                 totalThreshold : Long = 0
               ) : DynamicFrame
```

Renvoie un nouveau `DynamicFrame` avec les partitions `numPartitions`.

def resolveChoice

```
def resolveChoice( specs : Seq[Product2[String, String]] = Seq.empty[ResolveSpec],
                  choiceOption : Option[ChoiceOption] = None,
                  database : Option[String] = None,
                  tableName : Option[String] = None,
                  transformationContext : String = "",
                  callSite : CallSite = CallSite("Not provided", ""),
                  stageThreshold : Long = 0,
                  totalThreshold : Long = 0
                ) : DynamicFrame
```

- `choiceOption` — Action à appliquer aux colonnes `ChoiceType` non listées dans la séquence des spécifications.
- `database` — base de données Data Catalog à utiliser avec l'action `match_catalog`.
- `tableName` — table Data Catalog à utiliser avec l'action `match_catalog`.

Renvoie un nouveau `DynamicFrame` en remplaçant un ou plusieurs `ChoiceType` avec un type plus spécifique.

Il existe deux façons d'utiliser `resolveChoice`. La première consiste à spécifier une séquence de colonnes spécifiques et la façon de les résoudre. Celles-ci sont spécifiés en tant que tuples composés de paires (colonne, action).

Les actions possibles sont les suivantes :

- `cast:type` — Tente de convertir toutes les valeurs dans le type spécifié.
- `make_cols` – Convertit chaque type distinct en une colonne portant le nom `columnName_type`.
- `make_struct` — Convertit une colonne en une structure avec des clés pour chaque type distinct.
- `project:type` — Retient uniquement les valeurs du type spécifié.

L'autre mode pour `resolveChoice` consiste à spécifier une seule résolution pour tous les `ChoiceTypes`. Vous pouvez utiliser cela lorsque la liste complète des `ChoiceTypes` est inconnue avant l'exécution. En plus des actions répertoriées précédemment, ce mode prend également en charge l'action suivante :

- `match_catalogChoiceType` — Tente de convertir chaque dans le type correspondant de la table de catalogue spécifiée.

Exemples :

Résolvez la colonne `user.id` en la convertissant en `int` et faites que le champ `address` conserve uniquement les structs.

```
{{{  
  df.resolveChoice(specs = Seq(("user.id", "cast:int"), ("address", "project:struct")))  
}}}
```

Résolvez tous les objets `ChoiceType` en convertissant chaque choix en colonne séparée.

```
{{{  
  df.resolveChoice(choiceOption = Some(ChoiceOption("make_cols")))  
}}}
```

Résolvez tous les objets `ChoiceType` en les convertissant dans les types de la table de catalogue spécifiée.

```
{{{  
  df.resolveChoice(choiceOption = Some(ChoiceOption("match_catalog")),  
                   database = Some("my_database"),  
                   tableName = Some("my_table"))  
}}}
```

def schema

```
def schema : Schema
```

Renvoie le schéma du `DynamicFrame`.

Le schéma renvoyé est assuré de contenir chaque champ présent dans un enregistrement de ce `DynamicFrame`. Mais dans un petit nombre de cas, il peut aussi contenir des champs supplémentaires. La méthode [unnest](#) peut être utilisée pour « resserrer » le schéma basé sur les enregistrements du `DynamicFrame`.

def selectField

```
def selectField( fieldName : String,  
                transformationContext : String = "",  
                callSite : CallSite = CallSite("Not provided", ""),  
                stageThreshold : Long = 0,
```

```
totalThreshold : Long = 0
) : DynamicFrame
```

Renvoie un champ unique comme `DynamicFrame`.

def selectFields

```
def selectFields( paths : Seq[String],
                  transformationContext : String = "",
                  callSite : CallSite = CallSite("Not provided", ""),
                  stageThreshold : Long = 0,
                  totalThreshold : Long = 0
                ) : DynamicFrame
```

- paths — Séquence de noms de colonnes à sélectionner.

Renvoie un nouveau `DynamicFrame` contenant les colonnes spécifiées.

 Note

La méthode `selectFields` peut uniquement être utilisée pour sélectionner les colonnes de niveau supérieur. La méthode [applyMapping](#) peut être utilisée pour sélectionner les colonnes imbriquées.

def show

```
def show( numRows : Int = 20 ) : Unit
```

- numRows — Nombre de lignes à imprimer.

Imprime les lignes du `DynamicFrame` au format JSON.

Définissez par simplifier `DDBJson`

DynamoDB exporte avec AWS Glue Le connecteur d'exportation DynamoDB génère des fichiers JSON contenant des structures imbriquées spécifiques. Pour plus d'informations, consultez la section [Objets de données](#). `simplifyDDBJson` Simplifie les colonnes imbriquées dans ce type de données et renvoie une nouvelle colonne simplifiée `DynamicFrame`. `DynamicFrame` S'il existe

plusieurs types ou si un type de carte est contenu dans un type de liste, les éléments de la liste ne seront pas simplifiés. Cette méthode prend uniquement en charge les données au format JSON d'exportation DynamoDB. envisagez d'effectuer des modifications similaires sur d'autres types de données.

```
def simplifyDDBJson() : DynamicFrame
```

Cette méthode ne prend aucun paramètre.

Exemple d'entrée

Tenez compte du schéma suivant généré par une exportation DynamoDB :

```
root
|-- Item: struct
|   |-- parentMap: struct
|   |   |-- M: struct
|   |   |   |-- childMap: struct
|   |   |   |   |-- M: struct
|   |   |   |   |   |-- appName: struct
|   |   |   |   |   |   |-- S: string
|   |   |   |   |   |   |-- packageName: struct
|   |   |   |   |   |   |   |-- S: string
|   |   |   |   |   |   |   |-- updatedAt: struct
|   |   |   |   |   |   |   |   |-- N: string
|   |   |-- strings: struct
|   |   |   |-- SS: array
|   |   |   |   |-- element: string
|   |   |-- numbers: struct
|   |   |   |-- NS: array
|   |   |   |   |-- element: string
|   |   |-- binaries: struct
|   |   |   |-- BS: array
|   |   |   |   |-- element: string
|   |   |-- isDDBJson: struct
|   |   |   |-- BOOL: boolean
|   |   |-- nullValue: struct
|   |   |   |-- NULL: boolean
```

Exemple de code

```
import com.amazonaws.services.glue.GlueContext
```



```

import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamoDbDataSink
import org.apache.spark.SparkContextimport scala.collection.JavaConverters._

object GlueApp {

  def main(sysArgs: Array[String]): Unit = {
    val glueContext = new GlueContext(SparkContext.getOrCreate())
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType = "dynamodb",
      options = JsonOptions(Map(
        "dynamodb.export" -> "ddb",
        "dynamodb.tableArn" -> "ddbTableARN",
        "dynamodb.s3.bucket" -> "exportBucketLocation",
        "dynamodb.s3.prefix" -> "exportBucketPrefix",
        "dynamodb.s3.bucketOwner" -> "exportBucketAccountID",
      ))
    ).getDynamicFrame()

    val simplified = dynamicFrame.simplifyDDBJson()
    simplified.printSchema()

    Job.commit()
  }
}

```

Exemple de sortie

La transformation `simplifyDDBJson` simplifie cette exportation ainsi :

```

root
|-- parentMap: struct
|   |-- childMap: struct
|   |   |-- appName: string
|   |   |-- packageName: string
|   |   |-- updatedAt: string
|-- strings: array
|   |-- element: string

```

```
|-- numbers: array
|   |-- element: string
|-- binaries: array
|   |-- element: string
|-- isDDBJson: boolean
|-- nullValue: null
```

def spigot

```
def spigot( path : String,
            options : JsonOptions = new JsonOptions("{}"),
            transformationContext : String = "",
            callSite : CallSite = CallSite("Not provided"),
            stageThreshold : Long = 0,
            totalThreshold : Long = 0
          ) : DynamicFrame
```

Transmettez la transformation qui renvoie les mêmes enregistrements, mais écrit un sous-ensemble d'enregistrements en tant qu'effet secondaire.

- **path** — chemin d'accès dans Amazon S3 dans lequel écrire la sortie, sous la forme `s3://bucket/path`.
- **options** — Carte `JsonOptions` facultative décrivant le comportement d'échantillonnage.

Renvoie un `DynamicFrame` contenant les mêmes enregistrements que celui-ci.

Par défaut, écrit 100 enregistrements arbitraires à l'emplacement spécifié par `path`. Ce comportement peut être personnalisé à l'aide de la carte `options`. Les clés valides incluent les suivantes :

- **topk** — spécifie le nombre total d'enregistrements écrits. La valeur par défaut est 100.
- **prob** — indique la probabilité (sous forme de décimale) qu'un enregistrement individuel soit inclus. La valeur par défaut est 1.

Par exemple, l'appel suivant échantillonne l'ensemble de données en sélectionnant chaque enregistrement avec une probabilité de 20 % et en s'arrêtant après l'écriture de 200 enregistrements.

```
{{{
```

```
df.spigot("s3://my_bucket/my_path", JsonOptions(Map("topk" -> 200, "prob" ->
0.2)))
}}
```

def splitFields

```
def splitFields( paths : Seq[String],
  transformationContext : String = "",
  callSite : CallSite = CallSite("Not provided", ""),
  stageThreshold : Long = 0,
  totalThreshold : Long = 0
) : Seq[DynamicFrame]
```

- paths — Chemins à inclure dans le premier DynamicFrame.

Renvoie une séquence de deux DynamicFrames. Le premier DynamicFrame contient les chemins d'accès spécifiés et le deuxième contient toutes les autres colonnes.

Exemple

Cet exemple prend une persons table DynamicFrame créée à partir de la legislators base de données du AWS Glue Data Catalog et la DynamicFrame divise en deux, les champs spécifiés étant placés dans le premier DynamicFrame et les champs restants dans un second DynamicFrame. L'exemple choisit ensuite le premier DynamicFrame parmi le résultat.

```
val InputFrame = glueContext.getCatalogSource(database="legislators",
  tableName="persons",
  transformationContext="InputFrame").getDynamicFrame()

val SplitField_collection = InputFrame.splitFields(paths=Seq("family_name", "name",
  "links.note",
  "links.url", "gender", "image", "identifiers.scheme", "identifiers.identifier",
  "other_names.lang",
  "other_names.note", "other_names.name"), transformationContext="SplitField_collection")

val ResultFrame = SplitField_collection(0)
```

def splitRows

```
def splitRows( paths : Seq[String],
  values : Seq[Any],
```

```

        operators : Seq[String],
        transformationContext : String,
        callSite : CallSite,
        stageThreshold : Long,
        totalThreshold : Long
    ) : Seq[DynamicFrame]

```

Fractionne les lignes en fonction des prédicats qui comparent les colonnes aux constantes.

- `paths` — Colonnes à utiliser pour la comparaison.
- `values` — Valeurs constantes à utiliser pour la comparaison.
- `operators` — Opérateurs à utiliser pour la comparaison.

Renvoie une séquence de deux `DynamicFrames`. Le premier contient les lignes pour lesquelles le prédicat a la valeur `true` et le deuxième contient celles pour lesquelles la valeur est `false`.

Les prédicats sont spécifiés en utilisant trois séquences : « `paths` » contient les noms de colonne (possiblement imbriqués), « `values` » contient les valeurs constantes de comparaison et « `operators` » contient les opérateurs à utiliser pour la comparaison. Les trois séquences doivent être de la même longueur : le même opérateur est utilisé pour comparer la même colonne à la même valeur.

Chaque opérateur doit être « `!=` », « `=` », « `<=` », « `<` », « `>=` » ou « `>` ».

Par exemple, l'appel suivant scinde une trame `DynamicFrame` afin que la première trame de sortie contienne les enregistrements des personnes de plus de 65 ans des États-Unis et que la deuxième contienne tous les autres enregistrements.

```

{{{
    df.splitRows(Seq("age", "address.country"), Seq(65, "USA"), Seq(">=", "="))
}}}

```

Déf `stageErrorsCount`

```
def stageErrorsCount
```

Renvoie le nombre d'enregistrements d'erreur créés pendant le calcul du `DynamicFrame`. Cela exclut les erreurs des opérations précédentes qui ont été transmises au `DynamicFrame` comme entrée.

def toDF

```
def toDF( specs : Seq[ResolveSpec] = Seq.empty[ResolveSpec] ) : DataFrame
```

Convertit le `DynamicFrame` en un `DataFrame` Apache Spark SQL avec le même schéma et les mêmes enregistrements.

Note

Étant donné que les `DataFrames` ne prennent pas en charge les `ChoiceTypes`, cette méthode convertit automatiquement les colonnes `ChoiceType` en `StructTypes`. Pour plus d'informations et pour connaître les options de résolution des choix, consultez [resolveChoice](#).

def unbox

```
def unbox( path : String,
          format : String,
          optionString : String = "{}",
          transformationContext : String = "",
          callSite : CallSite = CallSite("Not provided"),
          stageThreshold : Long = 0,
          totalThreshold : Long = 0
        ) : DynamicFrame
```

- `path` — colonne à analyser. Doit être de type `string` (chaîne) ou `binary` (binaire).
- `format` — Le format à utiliser pour l'analyse.
- `optionString` — Options à transmettre au format, telles que le séparateur CSV.

Analyse une chaîne ou une colonne binaire intégrée selon le format spécifié. Les colonnes analysées sont imbriquées sous une structure avec le nom de colonne d'origine.

Par exemple, supposons que vous ayez un fichier CSV avec une colonne JSON imbriquée.

```
name, age, address
Sally, 36, {"state": "NE", "city": "Omaha"}
...
```

Après une analyse initiale, vous obtenez une trame `DynamicFrame` avec le schéma suivant.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address: string
}}}
```

Vous pouvez appeler `unbox` au niveau de la colonne « `address` » pour analyser les composants spécifiques.

```
{{{
  df.unbox("address", "json")
}}}
```

Vous obtenez ainsi une trame `DynamicFrame` avec le schéma suivant.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address: struct
  |     |-- state: string
  |     |-- city: string
}}}
```

`def unnest`

```
def unnest( transformationContext : String = "",
            callSite : CallSite = CallSite("Not Provided"),
            stageThreshold : Long = 0,
            totalThreshold : Long = 0
            ) : DynamicFrame
```

Renvoie un nouveau `DynamicFrame` avec tous les structures imbriquées mises à plat. Les noms sont construits à l'aide du caractère « `.` » (point).

Par exemple, supposons que vous ayez une trame `DynamicFrame` avec le schéma suivant.

```
{{{
  root
```

```
|-- name: string
|-- age: int
|-- address: struct
|   |-- state: string
|   |-- city: string
}}
```

L'appel suivant désimbrique la struct « address ».

```
{{{
  df.unnest()
}}}
```

Le schéma obtenu est le suivant.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address.state: string
  |-- address.city: string
}}}
```

Cette méthode désimbrique également les structs imbriquées à l'intérieur des tableaux. Mais pour des raisons historiques, le nom de ces champs est précédé par le nom du tableau englobant et par « .val ».

Def Unnest DDBJson

```
unnestDDBJson(transformationContext : String = "",
               callSite : CallSite = CallSite("Not Provided"),
               stageThreshold : Long = 0,
               totalThreshold : Long = 0): DynamicFrame
```

Supprime l'imbrication des colonnes imbriquées dans un `DynamicFrame` qui se trouvent spécifiquement dans la structure JSON DynamoDB, et renvoie une nouvelle version non imbriquée `DynamicFrame`. Les colonnes d'un tableau de types de structure ne seront pas non-imbriquées. Notez qu'il s'agit d'un type spécifique de transformation non imbriquée qui se comporte différemment de la transformation `unnest` normale et nécessite que les données soient déjà dans la structure JSON DynamoDB. Pour plus d'informations, consultez [JSON DynamoDB](#).

Par exemple, le schéma d'une lecture d'exportation avec la structure JSON DynamoDB pourrait ressembler à ce qui suit :

```
root
|-- Item: struct
|   |-- ColA: struct
|   |   |-- S: string
|   |-- ColB: struct
|   |   |-- S: string
|   |-- ColC: struct
|   |   |-- N: string
|   |-- ColD: struct
|   |   |-- L: array
|   |   |-- element: null
```

La transformation `unnestDDBJson()` convertirait ceci en :

```
root
|-- ColA: string
|-- ColB: string
|-- ColC: string
|-- ColD: array
|   |-- element: null
```

L'exemple de code suivant montre comment utiliser le connecteur d'exportation AWS Glue DynamoDB, appeler un DynamoDB JSON `unnest` et imprimer le nombre de partitions :

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamoDbDataSink
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {

  def main(sysArgs: Array[String]): Unit = {
    val glueContext = new GlueContext(SparkContext.getOrCreate())
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
```



```
val dynamicFrame = glueContext.getSourceWithFormat(
  connectionType = "dynamodb",
  options = JsonOptions(Map(
    "dynamodb.export" -> "ddb",
    "dynamodb.tableArn" -> "<test_source>",
    "dynamodb.s3.bucket" -> "<bucket name>",
    "dynamodb.s3.prefix" -> "<bucket prefix>",
    "dynamodb.s3.bucketOwner" -> "<account_id of bucket>",
  ))
).getDynamicFrame()

val unnested = dynamicFrame.unnestDDBJson()
print(unnested.getNumPartitions())

Job.commit()
}
```

Déf withFrameSchema

```
def withFrameSchema( getSchema : () => Schema ) : DynamicFrame
```

- `getSchema` — fonction qui renvoie le schéma à utiliser. Spécifiée en tant que fonction de paramètre zéro pour reporter un calcul potentiellement onéreux.

Définit le schéma du `DynamicFrame` sur la valeur spécifiée. La fonction est principalement utilisée en interne pour éviter un recalcul du schéma coûteux. Le schéma transmis doit contenir toutes les colonnes présentes dans les données.

def withName

```
def withName( name : String ) : DynamicFrame
```

- `name` — Nouveau nom à utiliser.

Renvoie une copie du `DynamicFrame` avec un nouveau nom.

Déf withTransformationContext

```
def withTransformationContext( ctx : String ) : DynamicFrame
```

Renvoie une copie du `DynamicFrame` avec le contexte de transformation spécifié.

L' `DynamicFrame` objet

Package : `com.amazonaws.services.glue`

```
object DynamicFrame
```

def apply

```
def apply( df : DataFrame,  
          glueContext : GlueContext  
        ) : DynamicFrame
```

Déf emptyDynamicFrame

```
def emptyDynamicFrame( glueContext : GlueContext ) : DynamicFrame
```

def fromPythonRDD

```
def fromPythonRDD( rdd : JavaRDD[Array[Byte]],  
                  glueContext : GlueContext  
                ) : DynamicFrame
```

def ignoreErrors

```
def ignoreErrors( fn : DynamicRecord => DynamicRecord ) : DynamicRecord
```

def inlineErrors

```
def inlineErrors( msg : String,  
                 callSite : CallSite  
               ) : (DynamicRecord => DynamicRecord)
```

newFrameWithErreurs de définition

```
def newFrameWithErrors( prevFrame : DynamicFrame,
                        rdd : RDD[DynamicRecord],
                        name : String = "",
                        transformationContext : String = "",
                        callSite : CallSite,
                        stageThreshold : Long,
                        totalThreshold : Long
                      ) : DynamicFrame
```

AWS Glue Classe Scala DynamicRecord

Rubriques

- [def addField](#)
- [def dropField](#)
- [def setError](#)
- [def isError](#)
- [def getError](#)
- [def clearError](#)
- [def write](#)
- [def readFields](#)
- [def clone](#)
- [def schema](#)
- [def getRoot](#)
- [def toJson](#)
- [Déf getFieldNode](#)
- [def getField](#)
- [def hashCode](#)
- [def equals](#)
- [DynamicRecord objet](#)
- [RecordTraverser trait](#)

Package : com.amazonaws.services.glue

```
class DynamicRecord extends Serializable with Writable with Cloneable
```

Un `DynamicRecord` est une structure de données à description automatique qui représente une ligne de données de l'ensemble de données en cours de traitement. Elle est auto-descriptive en ce sens que vous pouvez obtenir le schéma de la ligne représentée par le `DynamicRecord` en inspectant l'enregistrement lui-même. Un `DynamicRecord` est similaire à un `Row` dans Apache Spark.

def addField

```
def addField( path : String,
              dynamicNode : DynamicNode
              ) : Unit
```

Ajoute un [DynamicNode](#) au chemin d'accès spécifié.

- path — Chemin d'accès du champ à ajouter.
- dynamicNode — [DynamicNode](#) à ajouter au chemin d'accès spécifié.

def dropField

```
def dropField(path: String, underRename: Boolean = false): Option[DynamicNode]
```

Supprime un [DynamicNode](#) du chemin spécifié et renvoie le nœud supprimé s'il n'y a pas un tableau dans le chemin d'accès spécifié.

- path — Chemin d'accès du champ à supprimer.
- underRenamedropField : valeur True si est appelé dans le cadre d'une transformation en nouveau nom ou false dans le cas contraire (false par défaut).

Retourne un `scala.Option Option` ([DynamicNode](#)).

def setError

```
def setError( error : Error )
```

Définit cet enregistrement en tant qu'enregistrement d'erreur, comme spécifié par le paramètre `error`.

Retourne un `DynamicRecord`.

`def isError`

```
def isError
```

Vérifie si cet enregistrement est un enregistrement d'erreur.

`def getError`

```
def getError
```

Obtient `Error` si l'enregistrement est un enregistrement d'erreur. Renvoie `scala.Some` `Some` (Erreur) si cet enregistrement est un enregistrement d'erreur ou `scala.None` dans le cas contraire.

`def clearError`

```
def clearError
```

Définissez `Error` sur `scala.None`.

`def write`

```
override def write( out : DataOutput ) : Unit
```

`def readFields`

```
override def readFields( in : DataInput ) : Unit
```

`def clone`

```
override def clone : DynamicRecord
```

Clone cet enregistrement en un nouveau `DynamicRecord` et le renvoie.

`def schema`

```
def schema
```

Obtient Schema en inspectant l'enregistrement.

def getRoot

```
def getRoot : ObjectNode
```

Obtient le ObjectNode racine pour l'enregistrement.

def toJson

```
def toJson : String
```

Obtient la chaîne JSON pour l'enregistrement.

Déf getFieldNode

```
def getFieldNode( path : String ) : Option[DynamicNode]
```

Obtient la valeur du champ au path spécifié comme option de DynamicNode.

Renvoie scala.Some Some ([DynamicNode](#)) si le champ existe, ou dans le cas contraire scala.None.None.

def getField

```
def getField( path : String ) : Option[Any]
```

Obtient la valeur du champ au path spécifié comme option de DynamicNode.

Retourne scala.Some Some (valeur).

def hashCode

```
override def hashCode : Int
```

def equals

```
override def equals( other : Any )
```

DynamicRecord objet

```
object DynamicRecord
```

Def apply

```
def apply( row : Row,  
          schema : SparkStructType )
```

Appliquez la méthode pour convertir un objet Row Apache Spark SQL en un [DynamicRecord](#).

- row – Spark SQL Row.
- schema — Schema de cette ligne.

Retourne un DynamicRecord.

RecordTraverser trait

```
trait RecordTraverser {  
  def nullValue(): Unit  
  def byteValue(value: Byte): Unit  
  def binaryValue(value: Array[Byte]): Unit  
  def booleanValue(value: Boolean): Unit  
  def shortValue(value: Short) : Unit  
  def intValue(value: Int) : Unit  
  def longValue(value: Long) : Unit  
  def floatValue(value: Float): Unit  
  def doubleValue(value: Double): Unit  
  def decimalValue(value: BigDecimal): Unit  
  def stringValue(value: String): Unit  
  def dateValue(value: Date): Unit  
  def timestampValue(value: Timestamp): Unit  
  def objectStart(length: Int): Unit  
  def objectKey(key: String): Unit  
  def objectEnd(): Unit  
  def mapStart(length: Int): Unit  
  def mapKey(key: String): Unit  
  def mapEnd(): Unit  
  def arrayStart(length: Int): Unit  
  def arrayEnd(): Unit  
}
```

AWS Glue Scala GlueContext APIs

Package : `com.amazonaws.services.glue`

```
class GlueContext extends SQLContext(sc) (  
    @transient val sc : SparkContext,  
    val defaultSourcePartitioner : PartitioningStrategy )
```

`GlueContext` Est le point d'entrée pour lire et écrire un [DynamicFrame](#) depuis et vers Amazon Simple Storage Service (Amazon S3), le catalogue de données AWS Glue, JDBC, etc. Cette classe fournit des fonctions d'utilitaire pour créer des objets [DataSource trait](#) et [DataSink](#) qui peuvent ensuite être utilisés pour lire et écrire les `DynamicFrame`.

Vous pouvez également utiliser `GlueContext` pour définir un nombre cible de partitions (par défaut 20) dans le `DynamicFrame` si le nombre de partitions créées à partir de la source est inférieure à un seuil minimal pour les partitions (par défaut 10).

`addIngestionTimeColonnes` def

```
def addIngestionTimeColumns(  
    df : DataFrame,  
    timeGranularity : String = "") : DataFrame
```

Ajoute des colonnes de temps d'ingestion, telles que `ingest_year`, `ingest_month`, `ingest_day`, `ingest_hour`, `ingest_minute` à l'entrée `DataFrame`. Cette fonction est automatiquement générée dans le script généré par AWS Glue lorsque vous spécifiez une table de catalogue de données avec Amazon S3 comme cible. Cette fonction met automatiquement à jour la partition avec les colonnes de temps d'ingestion sur la table de sortie. Cela permet aux données de sortie d'être automatiquement partitionnées à l'heure d'ingestion sans nécessiter de colonnes d'heure d'ingestion explicites dans les données d'entrée.

- `dataFrame` – `dataFrame` auquel ajouter les colonnes de temps d'ingestion.
- `timeGranularity` — granularité des colonnes de temps. Les valeurs valides sont « `day` », « `hour` » et « `minute` ». Par exemple, si « `hour` » est transmis à la fonction, les colonnes de temps « `ingest_year` », « `ingest_month` », « `ingest_day` » et « `ingest_hour` » seront ajoutées à l'original « `dataFrame` ».

Renvoie le bloc de données après l'ajout des colonnes de granularité temporelle.

Exemple :

```
glueContext.addIngestionTimeColumns(dataFrame, "hour")
```

def createDataFrame FromOptions

```
def createDataFrameFromOptions( connectionType : String,  
                                connectionOptions : JsonOptions,  
                                transformationContext : String = "",  
                                format : String = null,  
                                formatOptions : JsonOptions = JsonOptions.empty  
                                ) : DataSource
```

Renvoie un DataFrame créé avec la connexion et le format spécifiés. Utilisez cette fonction uniquement avec les sources AWS de streaming Glue.

- `connectionType` : type de connexion en streaming. Les valeurs valides sont `kinesis` et `kafka`.
- `connectionOptions` : options de connexion, qui sont différentes pour Kinesis et Kafka. Vous trouverez la liste de toutes les options de connexion pour chaque source de données de streaming sur la page [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#). Notez les différences suivantes dans les options de connexion en streaming :
 - Les sources de streaming Kinesis nécessitent `streamARN`, `startingPosition`, `inferSchema` et `classification`.
 - Les sources de streaming Kafka nécessitent `connectionName`, `topicName`, `startingOffsets`, `inferSchema` et `classification`.
- `transformationContext` : contexte de transformation à utiliser (facultatif).
- `format` : spécification de format (facultatif). Ceci est utilisé pour un Amazon S3 ou un AWS Glue connexion qui prend en charge plusieurs formats. Pour plus d'informations sur les formats pris en charge, veuillez consulter [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#).
- `formatOptions` : options de format pour le format spécifié. Pour de plus amples informations sur les options de formats pris en charge, veuillez consulter [Options de format de données](#).

Exemple pour la source de streaming Amazon Kinesis :

```
val data_frame_datasource0 =
```

```
glueContext.createDataFrameFromOptions(transformationContext = "datasource0",
  connectionType = "kinesis",
  connectionOptions = JsonOptions("""{"streamName": "example_stream", "startingPosition":
  "TRIM_HORIZON", "inferSchema": "true", "classification": "json"}"""))
```

Exemple pour la source de streaming Kafka :

```
val data_frame_datasource0 =
glueContext.createDataFrameFromOptions(transformationContext = "datasource0",
  connectionType = "kafka",
  connectionOptions = JsonOptions("""{"connectionName": "example_connection",
  "topicName": "example_topic", "startingPosition": "earliest", "inferSchema": "false",
  "classification": "json", "schema": "`column1` STRING, `column2` STRING"}"""))
```

forEachBatch

forEachBatch(frame, batch_function, options)

S'applique à `batch_function` transmis à chaque micro-lot lu à partir de la source de streaming.

- `frame` — Le `DataFrame` contenant le micro-lot actuel.
- `batch_function` — fonction qui sera appliquée à chaque micro-lot.
- `options` — collection de paires clé-valeur qui contient des informations sur le traitement de micro-lots. Les options suivantes sont requises :
 - `windowSize` — durée de traitement de chaque lot.
 - `checkpointLocation` — emplacement dans lequel les points de contrôle sont stockés pour la tâche ETL en streaming.
 - `batchMaxRetries` – nombre maximum de nouvelles tentatives pour ce lot en cas d'échec. La valeur par défaut est 3. Cette option n'est configurable que pour Glue version 2.0 et ultérieure.

Exemple :

```
glueContext.forEachBatch(data_frame_datasource0, (dataFrame: Dataset[Row], batchId:
Long) =>
{
  if (dataFrame.count() > 0)
  {
    val datasource0 = DynamicFrame(glueContext.addIngestionTimeColumns(dataFrame,
"hour"), glueContext)
    // @type: DataSink
```

```

        // @args: [database = "tempdb", table_name = "fromoptionsoutput",
stream_batch_time = "100 seconds",
        //      stream_checkpoint_location = "s3://from-options-testing-eu-central-1/
fromOptionsOutput/checkpoint/",
        //      transformation_ctx = "datasink1"]
        // @return: datasink1
        // @inputs: [frame = datasource0]
        val options_datasink1 = JsonOptions(
            Map("partitionKeys" -> Seq("ingest_year", "ingest_month", "ingest_day",
"ingest_hour"),
                "enableUpdateCatalog" -> true))
        val datasink1 = glueContext.getCatalogSink(
            database = "tempdb",
            tableName = "fromoptionsoutput",
            redshiftTmpDir = "",
            transformationContext = "datasink1",
            additionalOptions = options_datasink1.writeDynamicFrame(datasource0)
        )
    }, JsonOptions("""{"windowSize" : "100 seconds",
        "checkpointLocation" : "s3://from-options-testing-eu-central-1/
fromOptionsOutput/checkpoint/"}"""))

```

def getCatalogSink

```

def getCatalogSink( database : String,
    tableName : String,
    redshiftTmpDir : String = "",
    transformationContext : String = ""
    additionalOptions: JsonOptions = JsonOptions.empty,
    catalogId: String = null
) : DataSink

```

Crée un [DataSink](#) qui écrit dans un emplacement spécifié dans une table définie dans Data Catalog.

- **database** – Nom de base de données dans le catalogue de données.
- **tableName** – Nom de la table dans le catalogue de données.
- **redshiftTmpDir** – Répertoire intermédiaire temporaire à utiliser avec certains récepteurs de données. Valeur définie sur vide par défaut.
- **transformationContext** – Contexte de transformation associé au récepteur à utiliser par les signets de la tâche. Valeur définie sur vide par défaut.
- **additionalOptions**— Des options supplémentaires sont proposées à AWS Glue.

- `catalogId` — ID du catalogue (ID du compte) Data Catalog auquel vous accédez. Lorsque la valeur est null, l'ID de compte par défaut de l'appelant est utilisé.

Renvoie le `DataSink`.

def `getCatalogSource`

```
def getCatalogSource( database : String,
                      tableName : String,
                      redshiftTmpDir : String = "",
                      transformationContext : String = ""
                      pushDownPredicate : String = " "
                      additionalOptions: JsonOptions = JsonOptions.empty,
                      catalogId: String = null
                      ) : DataSource
```

Crée un [DataSource trait](#) qui lit les données à partir d'une définition de table dans Data Catalog.

- `database` — nom de la base de données dans Data Catalog.
- `tableName` – Nom de la table dans le catalogue de données.
- `redshiftTmpDir` – Répertoire intermédiaire temporaire à utiliser avec certains récepteurs de données. Valeur définie sur vide par défaut.
- `transformationContext` – Contexte de transformation associé au récepteur à utiliser par les signets de la tâche. Valeur définie sur vide par défaut.
- `pushDownPredicate` – Filtre les partitions sans avoir à répertorier ni lire tous les fichiers de votre jeu de données. Pour plus d'informations, consultez [Préfiltrage à l'aide des prédicats pushdown](#).
- `additionalOptions` — Ensemble de paires nom-valeur facultatives. Les options possibles comprennent celles répertoriées dans [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#), sauf pour `endpointUrl`, `streamName`, `bootstrap.servers`, `security.protocol`, `topicName`, `classification` et `delimiter`. Est une autre option prise en charge `catalogPartitionPredicate`:

`catalogPartitionPredicate` – Vous pouvez passer une expression de catalogue à filtrer en fonction des colonnes d'index. Cela envoie le filtrage du côté serveur. Pour plus d'informations, consultez [AWS Glue Indexes](#) de partition. Notez que `push_down_predicate` et `catalogPartitionPredicate` utilisent des syntaxes différentes. Le premier utilise la syntaxe standard SQL Spark et le dernier utilise l'analyseur JSQL.

- `catalogId` — ID du catalogue (ID du compte) Data Catalog auquel vous accédez. Lorsque la valeur est null, l'ID de compte par défaut de l'appelant est utilisé.

Renvoie le `DataSource`.

Exemple pour la source de streaming

```
val data_frame_datasource0 = glueContext.getCatalogSource(  
  database = "tempdb",  
  tableName = "test-stream-input",  
  redshiftTmpDir = "",  
  transformationContext = "datasource0",  
  additionalOptions = JsonOptions("""{  
    "startingPosition": "TRIM_HORIZON", "inferSchema": "false"}""")  
).getDataFrame()
```

def get JDBC Sink

```
def getJDBCSink( catalogConnection : String,  
  options : JsonOptions,  
  redshiftTmpDir : String = "",  
  transformationContext : String = "",  
  catalogId: String = null  
  ) : DataSink
```

Crée un [DataSink](#) qui écrit dans une base de données JDBC spécifiée d'un objet `Connection` dans Data Catalog. L'objet `Connection` comporte des informations de connexion pour se connecter à un récepteur JDBC incluant l'URL, le nom d'utilisateur, le mot de passe, le VPC, le sous-réseau et les groupes de sécurité.

- `catalogConnection` – Nom de la connexion dans le catalogue de données qui contient l'URL JDBC sur laquelle écrire.
- `options` – Chaîne de paires nom-valeur JSON qui fournissent des informations supplémentaires nécessaires pour écrire dans un magasin de données JDBC. Cela consiste notamment à :
 - `dbtable` (obligatoire) — Nom de la table JDBC. Pour les magasins de données JDBC qui prennent en charge les schémas dans une base de données, spécifiez `schema.table-name`. Si aucun schéma n'est fourni, c'est le schéma « public » par défaut qui est utilisé. L'exemple suivant illustre un paramètre d'options qui pointe sur un schéma nommé `test` et une table nommée `test_table` dans la base de données `test_db`.

```
options = JsonOptions("""{"dbtable": "test.test_table", "database": "test_db"}""")
```

- **database** (obligatoire) — Nom de la base de données JDBC.
- Toutes les options supplémentaires transmises directement à l'enregistreur JDBC SparkSQL. Pour plus d'informations, consultez [Redshift data source for Spark](#).
- **redshiftTmpDir** — répertoire intermédiaire temporaire à utiliser avec certains récepteurs de données. Valeur définie sur vide par défaut.
- **transformationContext** – Contexte de transformation associé au récepteur à utiliser par les signets de la tâche. Valeur définie sur vide par défaut.
- **catalogId** — ID du catalogue (ID du compte) Data Catalog auquel vous accédez. Lorsque la valeur est null, l'ID de compte par défaut de l'appelant est utilisé.

Exemple de code :

```
getJDBCSink(catalogConnection = "my-connection-name", options =  
  JsonOptions("""{"dbtable": "my-jdbc-table", "database": "my-jdbc-db"}"""),  
  redshiftTmpDir = "", transformationContext = "datasink4")
```

Renvoie le `DataSink`.

def `getSink`

```
def getSink( connectionType : String,  
             connectionOptions : JsonOptions,  
             transformationContext : String = ""  
           ) : DataSink
```

Crée un [DataSink](#) fichier qui écrit des données vers une destination telle qu'Amazon Simple Storage Service (Amazon S3), JDBC ou le AWS Glue Data Catalog, ou un flux de données Apache Kafka ou Amazon Kinesis.

- **connectionType** — Type de connexion. Consultez [the section called “Paramètres de connexion”](#).
- **connectionOptions** — Chaîne JSON de paires nom-valeur JSON qui fournissent des informations supplémentaires pour établir la connexion avec le récepteur de données. Consultez [the section called “Paramètres de connexion”](#).

- `transformationContext` – Contexte de transformation associé au récepteur à utiliser par les signets de la tâche. Valeur définie sur vide par défaut.

Renvoie le `DataSink`.

`getSinkWithFormat` def

```
def getSinkWithFormat( connectionType : String,
                       options : JsonOptions,
                       transformationContext : String = "",
                       format : String = null,
                       formatOptions : JsonOptions = JsonOptions.empty
                     ) : DataSink
```

Crée un [DataSink](#) fichier qui écrit des données vers une destination telle qu'Amazon S3, JDBC ou le catalogue de données, ou un flux de données Apache Kafka ou Amazon Kinesis. Définit également le format des données à écrire vers la destination.

- `connectionType` — Type de connexion. Consultez [the section called “Paramètres de connexion”](#).
- `options` — Chaîne JSON de paires nom-valeur JSON qui fournissent des informations supplémentaires pour établir une connexion avec le récepteur de données. Consultez [the section called “Paramètres de connexion”](#).
- `transformationContext` – Contexte de transformation associé au récepteur à utiliser par les signets de la tâche. Valeur définie sur vide par défaut.
- `format` — Format des données à écrire dans la destination.
- `formatOptions` – Chaîne JSON de paires nom-valeur qui fournissent des options supplémentaires pour le formatage des données à la destination. Consultez [Options de format de données](#).

Renvoie le `DataSink`.

`def getSource`

```
def getSource( connectionType : String,
               connectionOptions : JsonOptions,
               transformationContext : String = ""
               pushDownPredicate
```

```
) : DataSource
```

Crée un [DataSource trait](#) fichier qui lit les données d'une source telle qu'Amazon S3, JDBC ou le AWS Glue Data Catalog. Prend également en charge les sources de données de streaming Kafka et Kinesis.

- `connectionType` – Type de données de la source de données. Consultez [the section called “Paramètres de connexion”](#).
- `connectionOptions` — Chaîne de paires nom-valeur JSON qui fournissent des informations supplémentaires pour établir la connexion avec la source de données. Pour de plus amples informations, veuillez consulter [the section called “Paramètres de connexion”](#).

Une source de streaming Kinesis nécessite les options de connexion suivantes : `streamARN`, `startingPosition`, `inferSchema` et `classification`.

Une source de streaming Kafka nécessite les options de connexion suivantes : `connectionName`, `topicName`, `startingOffsets`, `inferSchema` et `classification`.

- `transformationContext` – Contexte de transformation associé au récepteur à utiliser par les signets de la tâche. Valeur définie sur vide par défaut.
- `pushDownPredicate` – Prédicat sur les colonnes de partition.

Renvoie le `DataSource`.

Exemple pour la source de streaming Amazon Kinesis :

```
val kinesisOptions = jsonOptions()
data_frame_datasource0 = glueContext.getSource("kinesis",
  kinesisOptions).getDataFrame()

private def jsonOptions(): JsonOptions = {
  new JsonOptions(
    s""""{"streamARN": "arn:aws:kinesis:eu-central-1:123456789012:stream/
fromOptionsStream",
      |"startingPosition": "TRIM_HORIZON",
      |"inferSchema": "true",
      |"classification": "json"}"""".stripMargin)
}
```

Exemple pour la source de streaming Kafka :


```
val kafkaOptions = jsonOptions()
val data_frame_datasource0 = glueContext.getSource("kafka",
  kafkaOptions).getDataFrame()

private def jsonOptions(): JsonOptions = {
  new JsonOptions(
    s""""{"connectionName": "ConfluentKafka",
      |"topicName": "kafka-auth-topic",
      |"startingOffsets": "earliest",
      |"inferSchema": "true",
      |"classification": "json"}"""".stripMargin)
}
```

getSourceWithFormat def

```
def getSourceWithFormat( connectionType : String,
                        options : JsonOptions,
                        transformationContext : String = "",
                        format : String = null,
                        formatOptions : JsonOptions = JsonOptions.empty
                        ) : DataSource
```

Crée un fichier [DataSource trait](#) qui lit les données d'une source telle qu'Amazon S3, JDBC ou le AWS Glue Data Catalog, et définit également le format des données stockées dans la source.

- **connectionType** – Type de données de la source de données. Consultez [the section called “Paramètres de connexion”](#).
- **options** – Chaîne de paires nom-valeur JSON qui fournissent des informations supplémentaires pour établir la connexion avec la source de données. Consultez [the section called “Paramètres de connexion”](#).
- **transformationContext** – Contexte de transformation associé au récepteur à utiliser par les signets de la tâche. Valeur définie sur vide par défaut.
- **format** – Format des données stockées à la source. Lorsque le **connectionType** est « s3 », vous pouvez également spécifier **format**. Peut être « avro », « csv », « grokLog », « ion », « json », « xml », « parquet » ou « orc ».
- **formatOptions** – Chaîne JSON de paires nom-valeur qui fournissent des options supplémentaires pour l'analyse des données à la source. Consultez [Options de format de données](#).

Renvoie le DataSource.

Exemples

Créez un DynamicFrame à partir d'une source de données qui est un fichier de valeurs séparées par des virgules (CSV) sur Amazon S3 :

```
val datasource0 = glueContext.getSourceWithFormat(  
    connectionType="s3",  
    options =JsonOptions(s""""{"paths": [ "s3://csv/nycflights.csv"]}"""),  
    transformationContext = "datasource0",  
    format = "csv",  
    formatOptions=JsonOptions(s""""{"withHeader":"true","separator": ","}""")  
).getDynamicFrame()
```

Créez un DynamicFrame à partir d'une source de données PostgreSQL à l'aide d'une connexion JDBC :

```
val datasource0 = glueContext.getSourceWithFormat(  
    connectionType="postgresql",  
    options =JsonOptions(s""""{  
        "url":"jdbc:postgresql://databasePostgres-1.rds.amazonaws.com:5432/testdb",  
        "dbtable": "public.company",  
        "redshiftTmpDir":"","  
        "user":"username",  
        "password":"password123"  
    }"""),  
    transformationContext = "datasource0").getDynamicFrame()
```

Créez un DynamicFrame à partir d'une source de données MySQL à l'aide d'une connexion JDBC :

```
val datasource0 = glueContext.getSourceWithFormat(  
    connectionType="mysql",  
    options =JsonOptions(s""""{  
        "url":"jdbc:mysql://databaseMysql-1.rds.amazonaws.com:3306/testdb",  
        "dbtable": "athenatest_nycflights13_csv",  
        "redshiftTmpDir":"","  
        "user":"username",  
        "password":"password123"  
    }"""),  
    transformationContext = "datasource0").getDynamicFrame()
```

def getSparkSession

```
def getSparkSession : SparkSession
```

Permet d'obtenir l'objet `SparkSession` associé à `GlueContext`. Utilisez cet `SparkSession` objet pour enregistrer des tables et UDFs pour l'utiliser avec `DataFrame Created From DynamicFrames`.

Renvoie le `SparkSession`.

def startTransaction

```
def startTransaction(readOnly: Boolean):String
```

Démarrer une nouvelle transaction. Appelle en interne l'API [Démarrer la transaction](#) Lake Formation.

- `readOnly` – Valeur booléenne indiquant si cette transaction doit être en lecture seule ou en lecture et en écriture. Les écritures effectuées à l'aide d'un ID de transaction en lecture seule seront rejetées. Les transactions en lecture seule n'ont pas besoin d'être validées.

Retourne l'ID de transaction.

def commitTransaction

```
def commitTransaction(transactionId: String, waitForCommit: Boolean): Boolean
```

Tentative de validation de la transaction spécifiée. `commitTransaction` peut être renvoyé avant la fin de la validation de la transaction. Appelle en interne la Lake Formation [commitTransaction](#) API.

- `transactionId` – (Chaîne) La transaction à valider.
- `waitForCommit` – (Booléen) Détermine si le `commitTransaction` retourne immédiatement. La valeur par défaut est `True`. Si elle est `false`, `commitTransaction` interroge et attend que la transaction soit validée. Le temps d'attente est limité à 1 minute en utilisant le backoff exponentiel avec un maximum de 6 tentatives de nouvelle tentative.

Renvoie une valeur de type Booléen pour indiquer si la validation a été effectuée ou non.

def cancelTransaction

```
def cancelTransaction(transactionId: String): Unit
```

Tentative d'annulation de la transaction spécifiée. Appelle en interne l'[CancelTransaction](#) API Lake Formation.

- `transactionId` – (Chaîne) La transaction à annuler.

Retourne une exception `TransactionCommittedException` si la transaction a déjà été validée.

def this

```
def this( sc : SparkContext,  
         minPartitions : Int,  
         targetPartitions : Int )
```

Crée un objet `GlueContext` utilisant le `SparkContext` spécifié, les partitions minimales et les partitions cible.

- `sc` — Le `SparkContext`.
- `minPartitions` — Nombre minimal de partitions.
- `targetPartitions` — Nombre cible de partitions.

Renvoie le `GlueContext`.

def this

```
def this( sc : SparkContext )
```

Crée un objet `GlueContext` avec le `SparkContext` fourni. Définit le nombre minimal de partitions à 10 et de partitions cibles à 20.

- `sc` — Le `SparkContext`.

Renvoie le `GlueContext`.

def this

```
def this( sparkContext : JavaSparkContext )
```

Crée un objet `GlueContext` avec le `JavaSparkContext` fourni. Définit le nombre minimal de partitions à 10 et de partitions cibles à 20.

- `sparkContext` — Le `JavaSparkContext`.

Renvoie le `GlueContext`.

`MappingSpec`

Package : `com.amazonaws.services.glue`

`MappingSpec` classe de cas

```
case class MappingSpec( sourcePath: SchemaPath,
                        sourceType: DataType,
                        targetPath: SchemaPath,
                        targetType: DataType
                        ) extends Product4[String, String, String, String] {
  override def _1: String = sourcePath.toString
  override def _2: String = ExtendedTypeName.fromDataType(sourceType)
  override def _3: String = targetPath.toString
  override def _4: String = ExtendedTypeName.fromDataType(targetType)
}
```

- `sourcePath` — `SchemaPath` du champ source.
- `sourceType` — `DataType` du champ source.
- `targetPath` — `SchemaPath` du champ cible.
- `targetType` — `DataType` du champ cible.

Un `MappingSpec` spécifie un mappage entre un chemin d'accès source et un type de données source, et un chemin cible et un type de données cible. La valeur du chemin d'accès source de l'image source s'affiche dans l'image cible du chemin cible. Le type de données source est converti dans le type de données cible.

Il s'étend depuis `Product4` afin que vous puissiez manipuler n'importe quel `Product4` dans votre interface `applyMapping`.

`MappingSpec` objet

```
object MappingSpec
```

L'objet `MappingSpec` contient les membres suivants :

Val orderingByTarget

```
val orderingByTarget: Ordering[MappingSpec]
```

Def apply

```
def apply( sourcePath : String,  
          sourceType : DataType,  
          targetPath : String,  
          targetType : DataType  
        ) : MappingSpec
```

Crée un MappingSpec.

- sourcePath — Représentation sous forme de chaîne du chemin d'accès source.
- sourceType – source DataType.
- targetPath — Représentation sous forme de chaîne du chemin d'accès cible.
- targetType – cible DataType.

Retourne un MappingSpec.

def apply

```
def apply( sourcePath : String,  
          sourceTypeString : String,  
          targetPath : String,  
          targetTypeString : String  
        ) : MappingSpec
```

Crée un MappingSpec.

- sourcePath — Représentation sous forme de chaîne du chemin d'accès source.
- sourceType — Représentation sous forme de chaîne du type de données source.
- targetPath — Représentation sous forme de chaîne du chemin d'accès cible.
- targetType — Représentation sous forme de chaîne du type de données cible.

Renvoie un MappingSpec.

Def apply

```
def apply( product : Product4[String, String, String, String] ) : MappingSpec
```

Crée un MappingSpec.

- `product` — Product4 du chemin d'accès source, type de données source, chemin d'accès cible et type de données cible.

Retourne un MappingSpec.

AWS Glue Scala ResolveSpec APIs

Rubriques

- [ResolveSpec objet](#)
- [ResolveSpec classe de cas](#)

Package : `com.amazonaws.services.glue`

ResolveSpec objet

ResolveSpec

```
object ResolveSpec
```

def

```
def apply( path : String,  
          action : String  
          ) : ResolveSpec
```

Crée un ResolveSpec.

- `path` — Représentation sous forme de chaîne du champ de choix qui doit être résolu.
- `action` — action de résolution. L'action peut être `Project`, `KeepAsStruct` ou `Cast`.

Renvoie le ResolveSpec.

def

```
def apply( product : Product2[String, String] ) : ResolveSpec
```

Crée un ResolveSpec.

- product – Product2 de : chemin d'accès source, action de résolution.

Renvoie le ResolveSpec.

ResolveSpec classe de cas

```
case class ResolveSpec extends Product2[String, String] (  
    path : SchemaPath,  
    action : String )
```

Crée un ResolveSpec.

- path — Le SchemaPath du champ de choix qui doit être résolu.
- action — action de résolution. L'action peut être Project, KeepAsStruct ou Cast.

ResolveSpec méthodes def

```
def _1 : String
```

```
def _2 : String
```

AWS Glue Scala ArrayNode APIs

Package : com.amazonaws.services.glue.types

ArrayNode classe de cas

ArrayNode

```
case class ArrayNode extends DynamicNode (  
    value : ArrayBuffer[DynamicNode] )
```


ArrayNode méthodes def

```
def add( node : DynamicNode )
```

```
def clone
```

```
def equals( other : Any )
```

```
def get( index : Int ) : Option[DynamicNode]
```

```
def getValue
```

```
def hashCode : Int
```

```
def isEmpty : Boolean
```

```
def nodeType
```

```
def remove( index : Int )
```

```
def this
```

```
def toIterator : Iterator[DynamicNode]
```

```
def toJson : String
```

```
def update( index : Int,  
            node : DynamicNode )
```

AWS Glue Scala BinaryNode APIs

Package : `com.amazonaws.services.glue.types`

BinaryNode classe de cas

BinaryNode

```
case class BinaryNode extends ScalarNode(value, TypeCode.BINARY) (  
    value : Array[Byte] )
```

BinaryNode champs de val

- ordering

BinaryNode méthodes def

```
def clone
```

```
def equals( other : Any )
```

```
def hashCode : Int
```

AWS Glue Scala BooleanNode APIs

Package : com.amazonaws.services.glue.types

BooleanNode classe de cas

BooleanNode

```
case class BooleanNode extends ScalarNode(value, TypeCode.BOOLEAN) (  
    value : Boolean )
```

BooleanNode champs de val

- ordering

BooleanNode méthodes def

```
def equals( other : Any )
```

AWS Glue Scala ByteNode APIs

Package : com.amazonaws.services.glue.types

ByteNode classe de cas

ByteNode

```
case class ByteNode extends ScalarNode(value, TypeCode.BYTE) (  
    value : Byte )
```

ByteNode champs de val

- `ordering`

ByteNode méthodes def

```
def equals( other : Any )
```

AWS Glue Scala DateNode APIs

Package : `com.amazonaws.services.glue.types`

DateNode classe de cas

DateNode

```
case class DateNode extends ScalarNode(value, TypeCode.DATE) (  
    value : Date )
```

DateNode champs de val

- `ordering`

DateNode méthodes def

```
def equals( other : Any )
```

```
def this( value : Int )
```

AWS Glue Scala DecimalNode APIs

Package : `com.amazonaws.services.glue.types`

DecimalNode classe de cas

DecimalNode

```
case class DecimalNode extends ScalarNode(value, TypeCode.DECIMAL) (  
    value : BigDecimal )
```

DecimalNode champs de val

- ordering

DecimalNode méthodes def

```
def equals( other : Any )
```

```
def this( value : Decimal )
```

AWS Glue Scala DoubleNode APIs

Package : com.amazonaws.services.glue.types

DoubleNode classe de cas

DoubleNode

```
case class DoubleNode extends ScalarNode(value, TypeCode.DOUBLE) (  
    value : Double )
```

DoubleNode champs de val

- ordering

DoubleNode méthodes def

```
def equals( other : Any )
```

AWS Glue Scala DynamicNode APIs

Rubriques

- [DynamicNode classe](#)
- [DynamicNode objet](#)

Package : com.amazonaws.services.glue.types

DynamicNode classe

DynamicNode

```
class DynamicNode extends Serializable with Cloneable
```

DynamicNode méthodes def

```
def getValue : Any
```

Obtenir la valeur brute et la lier à l'enregistrement actuel :

```
def nodeType : TypeCode
```

```
def toJson : String
```

Méthode pour déboguer :

```
def toRow( schema : Schema,  
           options : Map[String, ResolveOption]  
         ) : Row
```

```
def typeName : String
```

DynamicNode objet

DynamicNode

```
object DynamicNode
```

DynamicNode méthodes def

```
def quote( field : String,  
           useQuotes : Boolean
```

```
) : String
```

```
def quote( node : DynamicNode,  
          useQuotes : Boolean  
          ) : String
```

EvaluateDataQuality classe

AWS Glue Data Quality est en version préliminaire pour AWS Glue et est sujet à modification.

Package : `com.amazonaws.services.glue.dq`

```
object EvaluateDataQuality
```

Def apply

```
def apply(frame: DynamicFrame,  
         ruleset: String,  
         publishingOptions: JsonOptions = JsonOptions.empty): DynamicFrame
```

Évalue un ensemble de règles de qualité des données par rapport à un `DynamicFrame`, et renvoie un nouveau `DynamicFrame` avec les résultats de l'évaluation. Pour en savoir plus sur AWS Glue Data Quality, consultez [AWS Glue Qualité des données](#).

- `frame` – `DynamicFrame` dont vous souhaitez évaluer la qualité des données.
- `ruleset` – Ensemble de règles DQDL (Data Quality Definition Language) au format de chaîne. Pour en savoir plus sur DQDL, consultez le guide [Référence DQDL \(Data Quality Definition Language\)](#).
- `publishingOptions` – Dictionnaire qui spécifie les options de publication suivantes des résultats et des métriques d'une évaluation :
 - `dataQualityEvaluationContext`— Chaîne qui indique l'espace de noms sous lequel AWS Glue doit publier Amazon CloudWatch les métriques et les résultats de qualité des données. Les statistiques agrégées apparaissent dans CloudWatch, tandis que les résultats complets apparaissent dans l'interface de AWS Glue Studio.
 - Obligatoire : non
 - Valeur par défaut : `default_context`

- `enableDataQualityCloudWatchMetrics`— Spécifie si les résultats de l'évaluation de la qualité des données doivent être publiés sur CloudWatch. Vous spécifiez un espace de noms pour les métriques à l'aide de l'option `dataQualityEvaluationContext`.
 - Obligatoire : non
 - Valeur par défaut : `False`
- `enableDataQualityResultsPublishing` – Spécifie si les résultats relatifs à la qualité des données doivent être visibles dans l'onglet Data Quality (Qualité des données) de l'interface AWS Glue Studio.
 - Obligatoire : non
 - Valeur par défaut : `True`
- `resultsS3Prefix`— Spécifie l'emplacement Amazon S3 où AWS Glue peut écrire les résultats de l'évaluation de la qualité des données.
 - Obligatoire : non
 - Valeur par défaut : `""` (chaîne vide)

exemple

L'exemple de code suivant montre comment évaluer la qualité des données pour `DynamicFrame` avant d'effectuer une transformation `SelectFields`. Le script vérifie que l'ensemble des règles de qualité des données sont conformes avant de tenter la transformation.

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._
import com.amazonaws.services.glue.dq.EvaluateDataQuality

object GlueApp {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    // @params: [JOB_NAME]
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
```

```
// Create DynamicFrame with data
val Legislators_Area = glueContext.getCatalogSource(database="legislators",
table="areas_json", transformationContext="S3bucket_node1").getDynamicFrame()

// Define data quality ruleset
val DQ_Ruleset = """
    Rules = [ColumnExists "id"]
    """

// Evaluate data quality
val DQ_Results = EvaluateDataQuality.apply(frame=Legislators_Area,
ruleset=DQ_Ruleset, publishingOptions=JsonOptions("""{"dataQualityEvaluationContext":
"Legislators_Area", "enableDataQualityMetrics": "true",
"enableDataQualityResultsPublishing": "true"}"""))
assert(DQ_Results.filter(_.getField("Outcome").contains("Failed")).count == 0,
"Failing DQ rules for Legislators_Area caused the job to fail.")

// Script generated for node Select Fields
val SelectFields_Results = Legislators_Area.selectFields(paths=Seq("id", "name"),
transformationContext="Legislators_Area")

Job.commit()
}
```

AWS Glue Scala FloatNode APIs

Package : com.amazonaws.services.glue.types

FloatNode classe de cas

FloatNode

```
case class FloatNode extends ScalarNode(value, TypeCode.FLOAT) (
    value : Float )
```

FloatNode champs de val

- ordering

FloatNode méthodes def

```
def equals( other : Any )
```

FillMissingValues classe

Package : com.amazonaws.services.glue.ml

```
object FillMissingValues
```

def apply

```
def apply(frame: DynamicFrame,  
          missingValuesColumn: String,  
          outputColumn: String = "",  
          transformationContext: String = "",  
          callSite: CallSite = CallSite("Not provided", ""),  
          stageThreshold: Long = 0,  
          totalThreshold: Long = 0): DynamicFrame
```

Remplit les valeurs manquantes d'un cadre dynamique dans une colonne spécifiée et renvoie un nouveau cadre avec des estimations dans une nouvelle colonne. Pour les lignes sans valeurs manquantes, la valeur de la colonne spécifiée est dupliquée dans la nouvelle colonne.

- **frame**— Le champ `DynamicFrame` dans lequel les valeurs manquantes doivent être remplies. Obligatoire.
- **missingValuesColumn** — colonne contenant les valeurs manquantes (valeurs `null` et chaînes vides). Obligatoire.
- **outputColumn** — nom de la nouvelle colonne qui contiendra les valeurs estimées pour toutes les lignes dont la valeur était manquante. Facultatif ; la valeur par défaut est la valeur de `missingValuesColumn` avec le suffixe `"_filled"`.
- **transformationContext** — chaîne unique utilisée pour identifier les informations sur l'état (facultatif).
- **callSite** — utilisé pour fournir les informations de contexte pour le signalement d'erreurs.
- **stageThreshold** — nombre maximal d'erreurs qui peuvent avoir lieu dans la transformation avant qu'elle ne soit arrêtée (facultatif ; la valeur par défaut est zéro).
- **totalThreshold** — nombre maximal d'erreurs pouvant se produire globalement avant que le processus de traitement des erreurs ne soit arrêté (facultatif ; la valeur par défaut est zéro).

Renvoie une nouvelle image dynamique avec une colonne supplémentaire qui contient des estimations pour les lignes avec des valeurs manquantes et la valeur actuelle pour les autres lignes.

FindMatches classe

Package : com.amazonaws.services.glue.ml

```
object FindMatches
```

def apply

```
def apply(frame: DynamicFrame,
          transformId: String,
          transformationContext: String = "",
          callSite: CallSite = CallSite("Not provided", ""),
          stageThreshold: Long = 0,
          totalThreshold: Long = 0,
          enforcedMatches: DynamicFrame = null): DynamicFrame,
computeMatchConfidenceScores: Boolean
```

Recherchez des correspondances dans une image d'entrée et renvoyez une nouvelle image avec une nouvelle colonne contenant un ID unique par groupe de correspondance.

- **frame**— L' `DynamicFrame` endroit où trouver des correspondances. Obligatoire.
- **transformId**— Un identifiant unique associé à la `FindMatches` transformation à appliquer au cadre d'entrée. Obligatoire.
- **transformationContext** — Identifiant de ce `DynamicFrame`. Le `transformationContext` est utilisé en tant que clé pour l'état de signet de tâche conservé d'une exécution à l'autre. Facultatif.
- **callSite** – Permet de fournir des informations contextuelles pour le signalement d'erreurs. Ces valeurs sont automatiquement définies lors de l'appel à partir de Python. Facultatif.
- **stageThreshold** – Nombre maximal d'enregistrements d'erreurs autorisés depuis le calcul du `DynamicFrame` avant de lever une exception, à l'exclusion des enregistrements présents dans le `DynamicFrame` précédent. Facultatif. La valeur par défaut est zéro.
- **totalThreshold** – Nombre maximal d'enregistrements d'erreur avant qu'une exception ne soit levée, y compris ceux des images précédentes. Facultatif. La valeur par défaut est zéro.
- **enforcedMatches** – Image pour les correspondances forcées. Facultatif. L'argument par défaut est `null`.

- `computeMatchConfidenceScores` — Valeur booléenne indiquant s'il faut calculer un score de confiance pour chaque groupe d'enregistrements correspondants. Facultatif. La valeur par défaut est `false`.

Renvoie une nouvelle image dynamique avec un identifiant unique affecté à chaque groupe d'enregistrements correspondants.

`FindIncrementalMatches` classe

Package : `com.amazonaws.services.glue.ml`

```
object FindIncrementalMatches
```

`def apply`

```
apply(existingFrame: DynamicFrame,
       incrementalFrame: DynamicFrame,
       transformId: String,
       transformationContext: String = "",
       callSite: CallSite = CallSite("Not provided", ""),
       stageThreshold: Long = 0,
       totalThreshold: Long = 0,
       enforcedMatches: DynamicFrame = null): DynamicFrame,
computeMatchConfidenceScores: Boolean
```

Recherchez des correspondances dans les images existantes et incrémentielles, et renvoyez une nouvelle image avec une colonne contenant un ID unique par groupe de correspondance.

- `existingframe` – Image existante à laquelle un ID correspondant a été attribué pour chaque groupe. Obligatoire.
- `incrementalframe` – Image incrémentielle utilisée pour rechercher des correspondances avec l'image existante. Obligatoire.
- `transformId`— Un identifiant unique associé à la `FindIncrementalMatches` transformation à appliquer aux trames d'entrée. Obligatoire.
- `transformationContext` — Identifiant de ce `DynamicFrame`. Le `transformationContext` est utilisé en tant que clé pour l'état de signet de tâche conservé d'une exécution à l'autre. Facultatif.

- `callSite` – Permet de fournir des informations contextuelles pour le signalement d'erreurs. Ces valeurs sont automatiquement définies lors de l'appel à partir de Python. Facultatif.
- `stageThreshold` – Nombre maximal d'enregistrements d'erreurs autorisés depuis le calcul du `DynamicFrame` avant de lever une exception, à l'exclusion des enregistrements présents dans le `DynamicFrame` précédent. Facultatif. La valeur par défaut est zéro.
- `totalThreshold` – Nombre maximal d'enregistrements d'erreur avant qu'une exception ne soit levée, y compris ceux des images précédentes. Facultatif. La valeur par défaut est zéro.
- `enforcedMatches` – Image pour les correspondances forcées. Facultatif. L'argument par défaut est `null`.
- `computeMatchConfidenceScores` — Valeur booléenne indiquant s'il faut calculer un score de confiance pour chaque groupe d'enregistrements correspondants. Facultatif. La valeur par défaut est `false`.

Renvoie une nouvelle image dynamique avec un identifiant unique affecté à chaque groupe d'enregistrements correspondants.

AWS Glue Scala IntegerNode APIs

Package : `com.amazonaws.services.glue.types`

IntegerNode classe de cas

IntegerNode

```
case class IntegerNode extends ScalarNode(value, TypeCode.INT) (  
    value : Int )
```

IntegerNode champs de val

- `ordering`

IntegerNode méthodes def

```
def equals( other : Any )
```

AWS Glue Scala LongNode APIs

Package : `com.amazonaws.services.glue.types`

LongNode classe de cas

LongNode

```
case class LongNode extends ScalarNode(value, TypeCode.LONG) (  
    value : Long )
```

LongNode champs de val

- `ordering`

LongNode méthodes def

```
def equals( other : Any )
```

AWS Glue Scala MapLikeNode APIs

Package : `com.amazonaws.services.glue.types`

MapLikeNode classe

MapLikeNode

```
class MapLikeNode extends DynamicNode (  
    value : mutable.Map[String, DynamicNode] )
```

MapLikeNode méthodes def

```
def clear : Unit
```

```
def get( name : String ) : Option[DynamicNode]
```

```
def getValue
```

```
def has( name : String ) : Boolean
```

```
def isEmpty : Boolean
```

```
def put( name : String,  
        node : DynamicNode  
        ) : Option[DynamicNode]
```

```
def remove( name : String ) : Option[DynamicNode]
```

```
def toIterator : Iterator[(String, DynamicNode)]
```

```
def toJson : String
```

```
def toJson( useQuotes : Boolean ) : String
```

Exemple : Soit le fichier JSON suivant :

```
{"foo": "bar"}
```

Si `useQuotes == true`, `toJson` génère `{"foo": "bar"}`. Si `useQuotes == false`, `toJson` génère `{foo: bar}` @return.

AWS Glue Scala MapNode APIs

Package : `com.amazonaws.services.glue.types`

MapNode classe de cas

MapNode

```
case class MapNode extends MapLikeNode(value) (  
    value : mutable.Map[String, DynamicNode] )
```

MapNode méthodes def

```
def clone
```

```
def equals( other : Any )
```

```
def hashCode : Int
```

```
def nodeType
```

```
def this
```

AWS Glue Scala NullNode APIs

Rubriques

- [NullNode classe](#)
- [NullNode objet du boîtier](#)

Package : com.amazonaws.services.glue.types

NullNode classe

NullNode

```
class NullNode
```

NullNode objet du boîtier

NullNode

```
case object NullNode extends NullNode
```

AWS Glue Scala ObjectNode APIs

Rubriques

- [ObjectNode objet](#)
- [ObjectNode classe de cas](#)

Package : com.amazonaws.services.glue.types

ObjectNode objet

ObjectNode

```
object ObjectNode
```

ObjectNode méthodes def

```
def apply( frameKeys : Set[String],  
          v1 : mutable.Map[String, DynamicNode],  
          v2 : mutable.Map[String, DynamicNode],  
          resolveWith : String  
        ) : ObjectNode
```

ObjectNode classe de cas

ObjectNode

```
case class ObjectNode extends MapLikeNode(value) (  
    val value : mutable.Map[String, DynamicNode] )
```

ObjectNode méthodes def

```
def clone
```

```
def equals( other : Any )
```

```
def hashCode : Int
```

```
def nodeType
```

```
def this
```

AWS Glue Scala ScalarNode APIs

Rubriques

- [ScalarNode classe](#)
- [ScalarNode objet](#)

Package : com.amazonaws.services.glue.types

ScalarNode classe

ScalarNode

```
class ScalarNode extends DynamicNode (
    value : Any,
    scalarType : TypeCode )
```

ScalarNode méthodes def

```
def compare( other : Any,
    operator : String
    ) : Boolean
```

```
def getValue
```

```
def hashCode : Int
```

```
def nodeType
```

```
def toJson
```

ScalarNode objet

ScalarNode

```
object ScalarNode
```

ScalarNode méthodes def

```
def apply( v : Any ) : DynamicNode
```

```
def compare( tv : Ordered[T],
    other : T,
    operator : String
    ) : Boolean
```

```
def compareAny( v : Any,  
               y : Any,  
               o : String )
```

```
def withEscapedSpecialCharacters( jsonToEscape : String ) : String
```

AWS Glue Scala ShortNode APIs

Package : `com.amazonaws.services.glue.types`

ShortNode classe de cas

ShortNode

```
case class ShortNode extends ScalarNode(value, TypeCode.SHORT) (  
    value : Short )
```

ShortNode champs de val

- `ordering`

ShortNode méthodes def

```
def equals( other : Any )
```

AWS Glue Scala StringNode APIs

Package : `com.amazonaws.services.glue.types`

StringNode classe de cas

StringNode

```
case class StringNode extends ScalarNode(value, TypeCode.STRING) (  
    value : String )
```

StringNode champs de val

- `ordering`

StringNode méthodes def

```
def equals( other : Any )
```

```
def this( value : UTF8String )
```

AWS Glue Scala TimestampNode APIs

Package : `com.amazonaws.services.glue.types`

TimestampNode classe de cas

TimestampNode

```
case class TimestampNode extends ScalarNode(value, TypeCode.TIMESTAMP) (  
    value : Timestamp )
```

TimestampNode champs de val

- `ordering`

TimestampNode méthodes def

```
def equals( other : Any )
```

```
def this( value : Long )
```

AWS Glue Scala GlueArgParser APIs

Package : `com.amazonaws.services.glue.util`

Objet GlueArgParser

GlueArgParser

```
object GlueArgParser
```

Stricte compatible avec la version Python de `utils.getResolvedOptions` dans le package `AWSGlueDataplanePython`.

GlueArgParser méthodes def

```
def getResolvedOptions( args : Array[String],  
                        options : Array[String]  
                        ) : Map[String, String]
```

```
def initParser( userOptionsSet : mutable.Set[String] ) : ArgumentParser
```

Exemple Extraction des arguments transmis à une tâche

Pour extraire les arguments d'une tâche, vous pouvez utiliser la méthode `getResolvedOptions`. Prenons l'exemple suivant, qui récupère un argument de tâche nommé `aws_region`.

```
val args = GlueArgParser.getResolvedOptions(sysArgs,  
      Seq("JOB_NAME","aws_region").toArray)  
Job.init(args("JOB_NAME"), glueContext, args.asJava)  
val region = args("aws_region")  
println(region)
```

AWS Glue Job Scala APIs

Package : `com.amazonaws.services.glue.util`

Objet Job

Job

```
object Job
```

Modes def Job

```
def commit
```

```
def init( jobName : String,  
          glueContext : GlueContext,  
          args : java.util.Map[String, String] = Map[String, String]()  
          ) : this.type
```

```
def init( jobName : String,  
         glueContext : GlueContext,  
         endpoint : String,  
         args : java.util.Map[String, String]  
       ) : this.type
```

```
def isInitialized
```

```
def reset
```

```
def runId
```

Fonctionnalités et optimisations pour la programmation AWS Glue pour les scripts Spark ETL

Les sections suivantes décrivent les techniques et les valeurs qui s'appliquent généralement à AWS Glue pour la programmation Spark ETL (extraction, transformation et chargement) dans n'importe quel langage.

Rubriques

- [Types de connexion et options pour l'ETL dans AWS Glue pour Spark](#)
- [Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark](#)
- [AWS Support de Glue Data Catalog pour les tâches Spark SQL](#)
- [Utilisation des marque-pages de tâche](#)
- [Utilisation de la détection des données sensibles en dehors de AWS Glue Studio](#)
- [AWS Glue API Visual Job](#)

Types de connexion et options pour l'ETL dans AWS Glue pour Spark

Entrée AWS Glue pour Spark, various PySpark et les méthodes et transformations Scala spécifient le type de connexion à l'aide d'un `connectionType` paramètre. Ils spécifient des options de connexion à l'aide d'un paramètre `connectionOptions` ou `options`.

Le paramètre `connectionType` peut prendre les valeurs indiquées dans le tableau suivant. Les valeurs de paramètre associées `connectionOptions` (ou `options`) pour chaque type sont

documentées dans les sections suivantes. Sauf indication contraire, les paramètres s'appliquent lorsque la connexion est utilisée comme source ou comme collecteur.

Pour obtenir un exemple de code qui illustre le paramétrage et l'utilisation des options de connexion, consultez la page d'accueil de chaque type de connexion.

connectionType	Se connecte à
dynamodb	Base de données Amazon DynamoDB
kinesis	Amazon Kinesis Data Streams
s3	Amazon S3
documentdb	Base de données Amazon DocumentDB (compatible avec MongoDB)
openSearch	Amazon OpenSearch Service .
redshift	Base de données Amazon Redshift
kafka	Kafka ou Amazon Managed Streaming for Apache Kafka
azurecosmos	Azure Cosmos pour NoSQL.
azuresql	Azure SQL.
bigquery	Google BigQuery.
mongodb	Base de données MongoDB , y compris MongoDB Atlas.
sqlserver	Base de données Microsoft SQL Server (consultez Connexions JDBC)
mysql	Base de données MySQL (consultez Connexions JDBC)
oracle	Base de données Oracle (consultez Connexions JDBC)
postgresql	Base de données PostgreSQL (consultez Connexions JDBC)
saphana	SAP HANA.
snowflake	Lac de données Snowflake

connectionType	Se connecte à
teradata	Teradata Vantage.
vertica	Vertica.
personnalisé.*	Magasins de données Spark, Athena ou JDBC (voir Valeurs personnalisées et AWS Marketplace ConnectionType)
marketplace.*	Magasins de données Spark, Athena ou JDBC (voir Valeurs personnalisées et AWS Marketplace ConnectionType)

Connexions DynamoDB

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire dans des tables de DynamoDB dans Glue. AWS Vous vous connectez à DynamoDB à l'aide des autorisations IAM associées à votre tâche Glue. AWS AWS Glue prend en charge l'écriture de données dans la table DynamoDB d'un autre AWS compte. Pour de plus amples informations, veuillez consulter [the section called “Accès entre régions et entre comptes aux tables DynamoDB”](#).

En plus du AWS Glue [Connecteur DynamoDB ETL](#), vous pouvez lire depuis DynamoDB à l'aide du connecteur d'exportation DynamoDB, qui appelle une demande DynamoDB et la stocke dans un emplacement Amazon ExportTableToPointInTime S3 que vous fournissez, au format [DynamoDB JSON](#). AWS Glue crée ensuite un DynamicFrame objet en lisant les données depuis le site d'exportation Amazon S3.

Le rédacteur DynamoDB est disponible dans AWS Glue version 1.0 ou versions ultérieures. Le AWS Glue Le connecteur d'exportation DynamoDB est disponible dans AWS Glue version 2.0 ou versions ultérieures.

Pour plus d'informations sur DynamoDB, consultez la [documentation Amazon DynamoDB](#).

Note

Le lecteur ETL DynamoDB ne prend pas en charge les filtres ou les prédicats pushdown.

Configuration de connexions DynamoDB

Pour vous connecter à DynamoDB AWS depuis Glue, accordez au rôle IAM associé à AWS votre tâche Glue l'autorisation d'interagir avec DynamoDB. Pour plus d'informations sur les autorisations requises pour lire ou écrire à partir de DynamoDB, consultez [Actions, ressources et clés de condition pour DynamoDB](#) dans la documentation IAM.

Dans les situations suivantes, vous avez peut-être besoin d'une configuration supplémentaire :

- Lorsque vous utilisez le connecteur d'exportation DynamoDB, vous devez configurer IAM pour que votre tâche puisse demander des exportations de tables DynamoDB. En outre, vous devrez identifier un compartiment Amazon S3 pour l'exportation et fournir les autorisations appropriées dans IAM pour que DynamoDB puisse y écrire, et pour que votre tâche AWS Glue puisse y lire. Pour plus d'informations, consultez [Demande d'exportation de table dans DynamoDB](#).
- Si votre tâche AWS Glue nécessite une connectivité Amazon VPC spécifique, utilisez le type de connexion NETWORK AWS Glue pour proposer des options réseau. L'accès à DynamoDB étant autorisé par IAM, il n'est pas nécessaire d'utiliser un type de connexion AWS Glue DynamoDB.

Lecture et écriture dans DynamoDB

Les exemples de code suivants montrent comment lire et écrire des tables DynamoDB. Ils montrent la lecture d'une table et l'écriture dans une autre table.

Python

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dyf = glue_context.create_dynamic_frame.from_options(
    connection_type="dynamodb",
    connection_options={"dynamodb.input.tableName": test_source,
                        "dynamodb.throughput.read.percent": "1.0",
                        "dynamodb.splits": "100"}
```



```
    }
  )
  print(dyf.getNumPartitions())

  glue_context.write_dynamic_frame_from_options(
    frame=dyf,
    connection_type="dynamodb",
    connection_options={"dynamodb.output.tableName": test_sink,
                        "dynamodb.throughput.write.percent": "1.0"}
  )
)

job.commit()
```

Scala

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamoDbDataSink
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {

  def main(sysArgs: Array[String]): Unit = {
    val glueContext = new GlueContext(SparkContext.getOrCreate())
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType = "dynamodb",
      options = JsonOptions(Map(
        "dynamodb.input.tableName" -> test_source,
        "dynamodb.throughput.read.percent" -> "1.0",
        "dynamodb.splits" -> "100"
      ))
    ).getDynamicFrame()

    print(dynamicFrame.getNumPartitions())
  }
}
```

```
val dynamoDbSink: DynamoDbDataSink = glueContext.getSinkWithFormat(  
    connectionType = "dynamodb",  
    options = JsonOptions(Map(  
        "dynamodb.output.tableName" -> test_sink,  
        "dynamodb.throughput.write.percent" -> "1.0"  
    ))  
).asInstanceOf[DynamoDbDataSink]  
  
dynamoDbSink.writeDynamicFrame(dynamicFrame)  
  
Job.commit()  
}  
  
}
```

Utilisation du connecteur d'exportation DynamoDB

Le connecteur d'exportation fonctionne mieux que le connecteur ETL lorsque la taille de la table DynamoDB est supérieure à 80 Go. De plus, étant donné que la demande d'exportation est effectuée en dehors des processus Spark dans un AWS Glue tâche, vous pouvez activer le [dimensionnement automatique des tâches AWS Glue](#) pour économiser l'utilisation du DPU lors de la demande d'exportation. Avec le connecteur d'exportation, vous n'avez pas non plus besoin de configurer le nombre de fractionnements pour le parallélisme de l'exécuteur Spark ou le pourcentage de lecture du débit DynamoDB.

Note

DynamoDB a des exigences spécifiques pour recourir aux demandes `ExportTableToPointInTime`. Pour plus d'informations, consultez [Demande d'exportation de table dans DynamoDB](#). Par exemple, Point-in-Time-Restore (PITR) doit être activé sur la table pour utiliser ce connecteur. Le connecteur DynamoDB prend également en charge le AWS KMS chiffrement pour les exportations DynamoDB vers Amazon S3. La saisie de votre configuration de sécurité dans la configuration de la tâche AWS Glue active AWS KMS le chiffrement pour une exportation DynamoDB. La clé KMS doit être située dans la même région que le compartiment Simple Storage Service (Amazon S3). Notez que des frais supplémentaires pour l'exportation DynamoDB et les coûts de stockage Simple Storage Service (Amazon S3) s'appliquent. Les données exportées dans Simple Storage Service (Amazon S3) sont conservées une fois l'exécution d'une tâche terminée, ce qui vous permet de les réutiliser sans exportations DynamoDB supplémentaires. L'une des

conditions requises pour utiliser ce connecteur est que point-in-time la restauration (PITR) soit activée pour la table.

Le connecteur ETL DynamoDB ou le connecteur d'exportation ne prennent pas en charge les filtres ou les prédicats pushdown à appliquer à la source DynamoDB.

Les exemples de code suivants montrent comment lire (via le connecteur d'exportation) et comment imprimer le nombre de partitions.

Python

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dyf = glue_context.create_dynamic_frame.from_options(
    connection_type="dynamodb",
    connection_options={
        "dynamodb.export": "ddb",
        "dynamodb.tableArn": test_source,
        "dynamodb.s3.bucket": bucket_name,
        "dynamodb.s3.prefix": bucket_prefix,
        "dynamodb.s3.bucketOwner": account_id_of_bucket,
    }
)
print(dyf.getNumPartitions())

job.commit()
```

Scala

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
```

```

import com.amazonaws.services.glue.DynamoDbDataSink
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {

  def main(sysArgs: Array[String]): Unit = {
    val glueContext = new GlueContext(SparkContext.getOrCreate())
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType = "dynamodb",
      options = JsonOptions(Map(
        "dynamodb.export" -> "ddb",
        "dynamodb.tableArn" -> test_source,
        "dynamodb.s3.bucket" -> bucket_name,
        "dynamodb.s3.prefix" -> bucket_prefix,
        "dynamodb.s3.bucketOwner" -> account_id_of_bucket,
      ))
    ).getDynamicFrame()

    print(dynamicFrame.getNumPartitions())

    Job.commit()
  }
}

```

Ces exemples montrent comment effectuer la lecture (via le connecteur d'exportation) et imprimer le nombre de partitions à partir d'une table AWS Glue Data Catalog comportant une dynamodb classification :

Python

```

import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions

```

```

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dynamicFrame = glue_context.create_dynamic_frame.from_catalog(
    database=catalog_database,
    table_name=catalog_table_name,
    additional_options={
        "dynamodb.export": "ddb",
        "dynamodb.s3.bucket": s3_bucket,
        "dynamodb.s3.prefix": s3_bucket_prefix
    }
)
print(dynamicFrame.getNumPartitions())

job.commit()

```

Scala

```

import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamoDbDataSink
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {

  def main(sysArgs: Array[String]): Unit = {
    val glueContext = new GlueContext(SparkContext.getOrCreate())
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    val dynamicFrame = glueContext.getCatalogSource(
      database = catalog_database,
      tableName = catalog_table_name,
      additionalOptions = JsonOptions(Map(
        "dynamodb.export" -> "ddb",
        "dynamodb.s3.bucket" -> s3_bucket,
        "dynamodb.s3.prefix" -> s3_bucket_prefix
      ))
    )
  }
}

```

```

    ))
    ).getDynamicFrame()
    print(dynamicFrame.getNumPartitions())
)

```

Simplification de l'utilisation de l'exportation DynamoDB au format JSON

Le DynamoDB exporte avec AWS Glue Le connecteur d'exportation DynamoDB génère des fichiers JSON contenant des structures imbriquées spécifiques. Pour plus d'informations, consultez la section [Objets de données](#). AWS Glue fournit une DynamicFrame transformation qui peut transformer ces structures en une easier-to-use forme destinée à des applications en aval.

La transformation peut être appelée de deux manières. Vous pouvez définir l'option de connexion "dynamodb.simplifyDDBJson" avec la valeur "true" lorsque vous appelez une méthode pour lire à partir de DynamoDB. Vous pouvez également appeler la transformation en tant que méthode disponible indépendamment dans la bibliothèque AWS Glue.

Tenez compte du schéma suivant généré par une exportation DynamoDB :

```

root
|-- Item: struct
|   |-- parentMap: struct
|   |   |-- M: struct
|   |   |   |-- childMap: struct
|   |   |   |   |-- M: struct
|   |   |   |   |   |-- appName: struct
|   |   |   |   |   |   |-- S: string
|   |   |   |   |   |   |-- packageName: struct
|   |   |   |   |   |   |   |-- S: string
|   |   |   |   |   |   |   |-- updatedAt: struct
|   |   |   |   |   |   |   |   |-- N: string
|   |   |-- strings: struct
|   |   |   |-- SS: array
|   |   |   |   |-- element: string
|   |   |-- numbers: struct
|   |   |   |-- NS: array
|   |   |   |   |-- element: string
|   |   |-- binaries: struct
|   |   |   |-- BS: array
|   |   |   |   |-- element: string
|   |   |-- isDDBJson: struct
|   |   |-- B00L: boolean

```

```
|      |-- nullValue: struct
|      |      |-- NULL: boolean
```

La transformation `simplifyDDBJson` simplifie cette exportation ainsi :

```
root
|-- parentMap: struct
|   |-- childMap: struct
|   |   |-- appName: string
|   |   |-- packageName: string
|   |   |-- updatedAt: string
|-- strings: array
|   |-- element: string
|-- numbers: array
|   |-- element: string
|-- binaries: array
|   |-- element: string
|-- isDDBJson: boolean
|-- nullValue: null
```

Note

`simplifyDDBJson` est disponible dans AWS Glue 3.0 et versions ultérieures. La transformation `unnestDDBJson` est également disponible pour simplifier l'exportation DynamoDB au format JSON. Nous encourageons les utilisateurs à passer de `simplifyDDBJson` à `unnestDDBJson`.

Configuration du parallélisme des opérations de DynamoDB

Pour améliorer les performances, vous pouvez régler certains paramètres disponibles pour le connecteur DynamoDB. Lorsque vous ajustez les paramètres de parallélisme, votre objectif est de maximiser l'utilisation des AWS Glue workers provisionnés. Ensuite, si vous avez besoin de plus de performances, nous vous recommandons d'étendre votre travail en augmentant le nombre de DPUs.

Vous pouvez modifier le parallélisme dans une opération de lecture de DynamoDB à l'aide du paramètre `dynamodb.splits` lorsque vous utilisez le connecteur ETL. Lors d'une tâche de lecture avec le connecteur d'exportation, vous n'avez pas besoin de configurer le nombre de fractionnements pour le parallélisme de l'exécuteur Spark. Vous pouvez modifier le parallélisme dans une opération d'écriture de DynamoDB avec `dynamodb.output.numParallelTasks`.

Lecture avec le connecteur ETL DynamoDB

Nous vous recommandons de calculer `dynamodb.splits` en fonction du nombre maximum d'employés défini dans la configuration de votre tâche et du calcul `numSlots` suivant. En cas de mise à l'échelle automatique, le nombre réel d'employés disponibles peut changer et passer en dessous de ce plafond. Pour plus d'informations sur la définition du nombre maximum d'employés, consultez Nombre d'employés (`NumberOfWorkers`) dans [the section called “Configuration des propriétés des tâches Spark”](#).

- `numExecutors = NumberOfWorkers - 1`

À des fins de contexte, un exécuteur est réservé au pilote Spark ; d'autres exécuteurs sont utilisés pour traiter les données.

- `numSlotsPerExecutor =`

AWS Glue 3.0 and later versions

- 4 si `WorkerType` a la valeur `G.1X`
- 8 si `WorkerType` a la valeur `G.2X`
- 16 si `WorkerType` a la valeur `G.4X`
- 32 si `WorkerType` a la valeur `G.8X`

AWS Glue 2.0 and legacy versions

- 8 si `WorkerType` a la valeur `G.1X`
- 16 si `WorkerType` a la valeur `G.2X`

- `numSlots = numSlotsPerExecutor * numExecutors`

Nous vous recommandons de définir `dynamodb.splits` sur le nombre d'emplacements disponibles, `numSlots`.

Écriture dans DynamoDB

Le paramètre `dynamodb.output.numParallelTasks` est utilisé pour déterminer le WCU par tâche Spark, à l'aide du calcul suivant :

```
permittedWcuPerTask = ( TableWCU * dynamodb.throughput.write.percent ) /  
dynamodb.output.numParallelTasks
```

Le dispositif d'écriture DynamoDB fonctionne de manière optimale si la configuration représente avec précision le nombre de tâches Spark écrites dans DynamoDB. Dans certains cas, il se peut que vous

avez besoin de remplacer le calcul par défaut afin d'améliorer les performances d'écriture. Si vous ne spécifiez pas ce paramètre, le WCU autorisé pour chaque tâche Spark est automatiquement calculé par la formule suivante :

- `numPartitions = dynamicframe.getNumPartitions()`
- `numSlots` (tel que défini précédemment dans cette section)
- `numParallelTasks = min(numPartitions, numSlots)`
- Exemple 1 : DPU = 10, = Norme. WorkerType L'entrée DynamicFrame comporte 100 partitions RDD.
 - `numPartitions = 100`
 - `numExecutors = (10 - 1) * 2 - 1 = 17`
 - `numSlots = 4 * 17 = 68`
 - `numParallelTasks = min(100, 68) = 68`
- Exemple 2. DPU = 10, = Norme. WorkerType L'entrée DynamicFrame comporte 20 partitions RDD.
 - `numPartitions = 20`
 - `numExecutors = (10 - 1) * 2 - 1 = 17`
 - `numSlots = 4 * 17 = 68`
 - `numParallelTasks = min(20, 68) = 20`

Note

Les jobs sur les anciennes versions de AWS Glue et ceux utilisant des outils Standard Workers nécessitent des méthodes différentes pour calculer le nombre d'emplacements. Si vous avez besoin d'optimiser les performances de ces tâches, nous vous recommandons de passer aux versions compatibles de AWS Glue.

Référence des options de connexion DynamoDB

Désigne une connexion à Amazon DynamoDB.

Les options de connexion sont différentes pour une connexion source et une connexion collecteur.

« `connectionType` » : « `dynamodb` » avec le connecteur ETL comme source

Utilisez les options de connexion suivantes en "`connectionType`": "`dynamodb`" tant que source, lorsque vous utilisez le connecteur ETL AWS Glue DynamoDB :

- "`dynamodb.input.tableName`" : (obligatoire) table DynamoDB à lire.
- "`dynamodb.throughput.read.percent`" : (Facultatif) Le pourcentage d'unités de capacité de lecture à utiliser. La valeur définie par défaut est « 0,5 ». Valeurs acceptées : de 0,1 à 1,5 inclus.
 - 0.5 représente le taux de lecture par défaut, ce qui signifie que AWS Glue essaiera de consommer la moitié de la capacité de lecture de la table. Si vous augmentez la valeur ci-dessus 0.5, AWS Glue augmente le taux de demandes ; la diminution de la valeur ci-dessous 0.5 diminue le taux de demandes de lecture. (La vitesse de lecture réelle dépend de facteurs tels que l'existence d'une distribution uniforme des clés dans la table DynamoDB.)
- Lorsque la table DynamoDB est en mode à la demande, AWS Glue gère la capacité de lecture de la table à 40000. Pour exporter une table volumineuse, nous vous recommandons de basculer votre table DynamoDB en mode à la demande.
- "`dynamodb.splits`" : (facultatif) définit en combien de fractionnements nous partitionnons cette table DynamoDB lors de la lecture. La valeur définie par défaut est « 1 ». Valeurs acceptées : de 1 à 1 000 000 inclus.

1 montre qu'il n'y a pas de parallélisme. Nous vous recommandons fortement de spécifier une valeur plus élevée pour de meilleures performances en utilisant la formule ci-dessous. Pour plus d'informations sur la définition appropriée d'une valeur, consultez [the section called "Parallélisme de DynamoDB"](#).

- "`dynamodb.sts.roleArn`" : (facultatif) l'ARN du rôle IAM à endosser pour l'accès entre comptes. Ce paramètre est disponible dans AWS Glue 1.0 ou version ultérieure.
- "`dynamodb.sts.roleSessionName`" : (facultatif) nom de séance STS. La valeur par défaut est définie sur « `glue-dynamodb-read-sts-session` ». Ce paramètre est disponible dans AWS Glue 1.0 ou version ultérieure.

« `ConnectionType` » : « `dynamodb` » avec AWS Glue Connecteur d'exportation DynamoDB en tant que source

Utilisez les options de connexion suivantes avec « `ConnectionType` » : « `dynamodb` » comme source, lorsque vous utilisez AWS Glue Connecteur d'exportation DynamoDB, disponible uniquement pour AWS Glue à partir de la version 2.0 :

- `"dynamodb.export"` : (Obligatoire) Une valeur de chaîne :
 - Si ce paramètre est défini sur `ddb` active AWS Glue Connecteur d'exportation DynamoDB dans lequel un `ExportTableToPointInTimeRequest` nouveau connecteur sera invoqué lors de AWS Glue travail. Une nouvelle exportation sera générée avec l'emplacement transmis depuis `dynamodb.s3.bucket` et `dynamodb.s3.prefix`.
 - Si ce paramètre est défini sur `s3` active AWS Glue Connecteur d'exportation DynamoDB, mais ignore la création d'une nouvelle exportation DynamoDB et utilise à la place le et `dynamodb.s3.bucket` comme emplacement Amazon S3 d'une `dynamodb.s3.prefix` ancienne exportation de cette table.
- `"dynamodb.tableArn"` : (obligatoire) table DynamoDB à lire.
- `"dynamodb.unnestDDBJson"` : (Facultatif) Par défaut : `false`. Valeurs valides : booléen. S'il est paramétré sur `true`, il effectue une transformation irréprochable de la structure JSON DynamoDB présente dans les exportations. Définir `"dynamodb.unnestDDBJson"` et `"dynamodb.simplifyDDBJson"` sur `true` en même temps constitue une erreur. Dans les AWS versions 3.0 et ultérieures, nous vous recommandons de l'utiliser `"dynamodb.simplifyDDBJson"` pour un meilleur comportement lors de la simplification des types de cartes DynamoDB. Pour de plus amples informations, veuillez consulter [the section called "Simplification de l'utilisation de l'exportation DynamoDB au format JSON"](#).
- `"dynamodb.simplifyDDBJson"` : (Facultatif) Par défaut : `false`. Valeurs valides : booléen. S'il est paramétré sur `true`, il effectue une transformation pour simplifier le schéma de la structure JSON DynamoDB présente dans les exportations. Cela a le même objectif que l'option `"dynamodb.unnestDDBJson"`, mais fournit une meilleure prise en charge des types de cartes DynamoDB ou même des types de cartes imbriqués dans votre table DynamoDB. Cette option est disponible dans AWS Glue 3.0 et versions ultérieures. Définir `"dynamodb.unnestDDBJson"` et `"dynamodb.simplifyDDBJson"` sur `true` en même temps constitue une erreur. Pour de plus amples informations, veuillez consulter [the section called "Simplification de l'utilisation de l'exportation DynamoDB au format JSON"](#).
- `"dynamodb.s3.bucket"` : (facultatif) Indique l'emplacement du compartiment Amazon S3 dans lequel le processus DynamoDB `ExportTableToPointInTime` doit être mené. Le format de fichier de l'exportation est DynamoDB JSON.
- `"dynamodb.s3.prefix"` : (Facultatif) Indique l'emplacement du préfixe Amazon S3 dans le compartiment Amazon S3 dans lequel les charges `ExportTableToPointInTime` de DynamoDB doivent être stockées. Si ni l'un `dynamodb.s3.prefix` ni l'autre ne `dynamodb.s3.bucket` sont spécifiés, ces valeurs utiliseront par défaut l'emplacement

du répertoire temporaire spécifié dans AWS Glue configuration des tâches. Pour plus d'informations, consultez la section [Paramètres spéciaux utilisés par AWS Glue](#).

- `"dynamodb.s3.bucketOwner"` : indique le propriétaire du compartiment nécessaire à l'accès Amazon S3 entre comptes.
- `"dynamodb.sts.roleArn"` : (facultatif) ARN du rôle IAM à endosser pour l'accès intercompte et/ou l'accès entre régions pour la table DynamoDB. Remarque : Le même ARN de rôle IAM sera utilisé pour accéder à l'emplacement Amazon S3 spécifié pour la demande de `ExportTableToPointInTime`.
- `"dynamodb.sts.roleSessionName"` : (facultatif) nom de séance STS. La valeur par défaut est définie sur « `glue-dynamodb-read-sts-session` ».
- `"dynamodb.exportTime"` (Facultatif) Valeurs valides : chaînes représentant des instants ISO-8601. `point-in-timeA` où l'exportation doit être effectuée.
- `"dynamodb.sts.region"` : (Obligatoire si vous passez un appel entre régions à l'aide d'un point de terminaison régional) Région hébergeant la table DynamoDB que vous souhaitez lire.

« `connectionType` » : « `dynamodb` » avec le connecteur ETL comme récepteur

Utilisez les options de connexion suivantes avec `"connectionType"`: `"dynamodb"` comme collecteur :

- `"dynamodb.output.tableName"` : (obligatoire) table DynamoDB où écrire.
- `"dynamodb.throughput.write.percent"` : (facultatif) pourcentage d'unités de capacité de lecture (WCU) à utiliser. La valeur définie par défaut est « 0,5 ». Valeurs acceptées : de 0,1 à 1,5 inclus.
- 0,5 représente le taux d'écriture par défaut, ce qui signifie que AWS Glue essaiera de consommer la moitié de la capacité d'écriture de la table. Si vous augmentez la valeur au-dessus de 0,5, AWS Glue augmente le taux de demandes ; la diminution de la valeur en dessous de 0,5 diminue le taux de demandes d'écriture. (La vitesse d'écriture réelle dépend de facteurs tels que l'existence d'une distribution uniforme des clés dans la table DynamoDB.)
- Lorsque la table DynamoDB est en mode à la demande, AWS Glue gère la capacité d'écriture de la table en tant que 40000. Pour importer une table volumineuse, nous vous recommandons de basculer votre table DynamoDB en mode à la demande.
- `"dynamodb.output.numParallelTasks"` : (facultatif) définit le nombre de tâches parallèles qui écrivent dans DynamoDB simultanément. Utilisé pour calculer le WCU permissif par tâche Spark. Dans la plupart des cas, AWS Glue calcule une valeur par défaut raisonnable pour cette

valeur. Pour de plus amples informations, veuillez consulter [the section called “Parallélisme de DynamoDB”](#).

- `"dynamodb.output.retry"` : (facultatif) définit le nombre de tentatives que nous effectuons lorsqu'il y a un `ProvisionedThroughputExceededException` de DynamoDB. La valeur définie par défaut est « 10 ».
- `"dynamodb.sts.roleArn"` : (facultatif) l'ARN du rôle IAM à endosser pour l'accès entre comptes.
- `"dynamodb.sts.roleSessionName"` : (facultatif) nom de séance STS. La valeur par défaut est définie sur « `glue-dynamodb-write-sts-session` ».

Accès entre régions et entre comptes aux tables DynamoDB

AWS Glue Les tâches ETL prennent en charge l'accès aux tables DynamoDB à la fois entre régions et entre comptes. AWS Glue Les tâches ETL permettent à la fois de lire les données de la table DynamoDB d'un autre AWS compte et d'écrire des données dans la table DynamoDB d'un autre AWS compte. AWS Glue permet également de lire à partir d'une table DynamoDB d'une autre région et d'écrire dans une table DynamoDB d'une autre région. Cette section donne des instructions sur la configuration de l'accès et fournit un exemple de script.

Les procédures de cette section font référence à un didacticiel IAM pour créer un rôle IAM et accorder l'accès au rôle. Le didacticiel explique également comment assumer un rôle, mais ici, vous utiliserez plutôt un script de tâche pour assumer le rôle dans AWS Glue. Ce didacticiel contient également des informations sur les pratiques générales relatives aux comptes multiples. Pour plus d'informations, voir [Tutoriel : Déléguer l'accès entre AWS comptes à l'aide de rôles IAM](#) dans le Guide de l'utilisateur IAM.

Créer un rôle

Suivez [l'étape 1 du didacticiel](#) pour créer un rôle IAM dans le compte A. Lors de la définition des autorisations du rôle, vous pouvez choisir d'attacher des politiques existantes telles que `AmazonDynamoDBReadOnlyAccess` ou `AmazonDynamoDBFullAccess` pour autoriser le rôle à lire DynamoDB ou écrire sur DynamoDB. L'exemple suivant illustre la création d'un rôle nommé `DynamoDBCrossAccessRole`, avec la politique d'autorisation `AmazonDynamoDBFullAccess`.

Accorder l'accès au rôle

Suivez [l'étape 2 du didacticiel](#) du Guide de l'utilisateur IAM pour permettre au compte B de basculer vers le rôle qui vient d'être créé. L'exemple suivant crée une politique avec l'instruction suivante :

```
{
  "Version": "2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": "sts:AssumeRole",
    "Resource": "<DynamoDBCrossAccessRole's ARN>"
  }
}
```

Vous pouvez ensuite associer cette politique à celle group/role/user que vous souhaitez utiliser pour accéder à DynamoDB.

Assumez le rôle dans AWS Glue script de tâche

Maintenant, vous pouvez vous connecter au compte B et créer un AWS Glue travail. Pour créer une tâche, reportez-vous aux instructions de la page [Configuration des propriétés des tâches pour les tâches Spark dans AWS Glue](#).

Dans le script de tâche, vous devez utiliser le paramètre `dynamodb.sts.roleArn` pour endosser le rôle `DynamoDBCrossAccessRole`. En supposant que ce rôle vous permet d'obtenir les informations d'identification temporaires, qui doivent être utilisées pour accéder à DynamoDB dans le compte B. Consultez ces exemples de scripts.

Pour une lecture entre comptes dans toutes les régions (connecteur ETL) :

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dyf = glue_context.create_dynamic_frame_from_options(
    connection_type="dynamodb",
    connection_options={
        "dynamodb.region": "us-east-1",
        "dynamodb.input.tableName": "test_source",
```

```

        "dynamodb.sts.roleArn": "<DynamoDBCrossAccessRole's ARN>"
    }
)
dyf.show()
job.commit()

```

Pour une lecture entre comptes dans toutes les régions (connecteur ETL) :

```

import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dyf = glue_context.create_dynamic_frame_from_options(
    connection_type="dynamodb",
    connection_options={
        "dynamodb.export": "ddb",
        "dynamodb.tableArn": "<test_source ARN>",
        "dynamodb.sts.roleArn": "<DynamoDBCrossAccessRole's ARN>"
    }
)
dyf.show()
job.commit()

```

Pour une lecture et une écriture entre comptes dans toutes les régions :

```

import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

```

```
dyf = glue_context.create_dynamic_frame_from_options(  
    connection_type="dynamodb",  
    connection_options={  
        "dynamodb.region": "us-east-1",  
        "dynamodb.input.tableName": "test_source"  
    }  
)  
dyf.show()  
  
glue_context.write_dynamic_frame_from_options(  
    frame=dyf,  
    connection_type="dynamodb",  
    connection_options={  
        "dynamodb.region": "us-west-2",  
        "dynamodb.output.tableName": "test_sink",  
        "dynamodb.sts.roleArn": "<DynamoDBCrossAccessRole's ARN>"  
    }  
)  
  
job.commit()
```

Connexions Kinesis

Vous pouvez utiliser une connexion Kinesis pour lire et écrire dans les flux de données Amazon Kinesis à l'aide des informations stockées dans une table du catalogue de données, ou en fournissant des informations pour accéder directement au flux de données. Vous pouvez lire les informations de Kinesis dans un Spark DataFrame, puis les convertir en Glue AWS . DynamicFrame Vous pouvez DynamicFrames écrire dans Kinesis au format JSON. Si vous accédez directement au flux de données, utilisez ces options pour fournir des informations sur la façon d'accéder au flux de données.

Si vous utilisez `getCatalogSource` ou `create_data_frame_from_catalog` pour consommer des enregistrements à partir d'une source de streaming Kinesis, la tâche dispose des informations relatives à la base de données Data Catalog et au nom de la table, et peut les utiliser pour obtenir certains paramètres de base pour la lecture à partir de la source de streaming Kinesis. Si vous utilisez `getSource`, `getSourceWithFormat`, `createDataFrameFromOptions` ou `create_data_frame_from_options`, vous devez spécifier ces paramètres de base à l'aide des options de connexion décrites ici.

Vous pouvez spécifier les options de connexion pour Kinesis à l'aide des arguments suivants pour les méthodes spécifiées dans la classe `GlueContext`.

- Scala
 - `connectionOptions` : utiliser avec `getSource`, `createDataFrameFromOptions`, `getSink`
 - `additionalOptions` : utiliser avec `getCatalogSource`, `getCatalogSink`
 - `options` : utiliser avec `getSourceWithFormat`, `getSinkWithFormat`
- Python
 - `connection_options` : utiliser avec `create_data_frame_from_options`, `write_dynamic_frame_from_options`
 - `additional_options` : utiliser avec `create_data_frame_from_catalog`, `write_dynamic_frame_from_catalog`
 - `options` : utiliser avec `getSource`, `getSink`

Pour les remarques et les restrictions concernant les tâches ETL de streaming, consultez [the section called “Restrictions et notes sur ETL en streaming”](#).

Configurer Kinesis

Pour vous connecter à un flux de données Kinesis dans le cadre d'une tâche AWS Glue Spark, vous aurez besoin de certaines conditions préalables :

- En cas de lecture, la tâche AWS Glue doit disposer d'autorisations IAM de niveau d'accès en lecture pour le flux de données Kinesis.
- En cas d'écriture, la tâche AWS Glue doit disposer d'autorisations IAM de niveau d'accès Write pour le flux de données Kinesis.

Dans certains cas, vous devrez configurer des prérequis supplémentaires :

- Si votre tâche AWS Glue est configurée avec des connexions réseau supplémentaires (généralement pour se connecter à d'autres ensembles de données) et que l'une de ces connexions fournit des options de réseau Amazon VPC, cela indiquera à votre tâche de communiquer via Amazon VPC. Dans ce cas, vous devrez également configurer votre flux de données Kinesis pour qu'il communique via Amazon VPC. Vous pouvez le faire en créant un point de terminaison d'un VPC d'interface entre votre Amazon VPC et votre flux de données Kinesis. Pour plus d'informations, consultez [Using Kinesis Data Streams with Interface VPC Endpoints](#).
- Lorsque vous spécifiez Amazon Kinesis Data Streams dans un autre compte, vous devez configurer les rôles et les stratégies pour autoriser l'accès intercompte. Pour de plus amples

informations, veuillez consulter la rubrique [Exemple : Lire à partir d'un flux Kinesis dans un autre compte](#).

Pour plus d'informations sur les prérequis de la tâche ETL de streaming, consultez [the section called "Tâches ETL en streaming"](#).

Exemple : lecture à partir de flux Kinesis

Exemple : lecture à partir de flux Kinesis

Utilisez conjointement avec [the section called "forEachBatch"](#).

Exemple pour la source de streaming Amazon Kinesis :

```
kinesis_options =  
  { "streamARN": "arn:aws:kinesis:us-east-2:777788889999:stream/fromOptionsStream",  
    "startingPosition": "TRIM_HORIZON",  
    "inferSchema": "true",  
    "classification": "json"  
  }  
data_frame_datasource0 =  
  glueContext.create_data_frame.from_options(connection_type="kinesis",  
    connection_options=kinesis_options)
```

Exemple : écriture dans Kinesis Streams

Exemple : lecture à partir de flux Kinesis

Utilisez conjointement avec [the section called "forEachBatch"](#).

Exemple pour la source de streaming Amazon Kinesis :

```
kinesis_options =  
  { "streamARN": "arn:aws:kinesis:us-east-2:777788889999:stream/fromOptionsStream",  
    "startingPosition": "TRIM_HORIZON",  
    "inferSchema": "true",  
    "classification": "json"  
  }  
data_frame_datasource0 =  
  glueContext.create_data_frame.from_options(connection_type="kinesis",  
    connection_options=kinesis_options)
```

Référence des options de connexion Kinesis

Désigne des options de connexion à Amazon Kinesis Data Streams.

Utilisez les options de connexion suivantes pour les sources de données en streaming Kinesis :

- "streamARN" (Obligatoire) Utilisé pour la lecture/l'écriture. ARN du flux de données Kinesis.
- "classification" (Obligatoire pour la lecture) Utilisé pour la lecture. Format de fichier utilisé par les données de l'enregistrement. Obligatoire, sauf s'il est fourni par le catalogue de données.
- "streamName" : (facultatif) utilisé pour la lecture. Nom du flux de données Kinesis à partir duquel lire. Utilisé avec `endpointUrl`.
- "endpointUrl" : (facultatif) utilisé pour la lecture. Par défaut : « `https://kinesis.us-east-1.amazonaws.com` ». AWS Point de terminaison du flux Kinesis. Vous n'avez pas besoin de modifier ce paramètre, sauf si vous vous connectez à une région spéciale.
- "partitionKey" : (facultatif) utilisé pour l'écriture. Clé de partition Kinesis utilisée lors de la production d'enregistrements.
- "delimiter" : (facultatif) utilisé pour la lecture. Séparateur de valeurs utilisé lorsque `classification` est CSV. La valeur par défaut est « , ».
- "startingPosition" : (facultatif) utilisé pour la lecture. La position de départ dans le flux de données Kinesis à partir duquel lire les données. Les valeurs possibles sont "latest", "trim_horizon", "earliest", ou une chaîne d'horodatage au format UTC dans le modèle yyyy-mm-ddTHH:MM:SSZ (où Z représente un décalage de fuseau horaire UTC avec un +/-). Par exemple : « 2023-04-04T08:00:00-04:00 ». La valeur par défaut est "latest". Remarque : la chaîne d'horodatage au format UTC pour n'"startingPosition" est prise en charge que pour la version 4.0 ou ultérieure de AWS Glue.
- "failOnDataLoss" : (facultatif) échec de la tâche si une partition active est manquante ou a expiré. La valeur par défaut est "false".
- "awsSTSRoleARN" : (facultatif) utilisé pour la lecture/l'écriture. Le nom de ressource Amazon (ARN) du rôle à assumer en utilisant AWS Security Token Service (AWS STS). Ce rôle doit disposer des autorisations nécessaires pour décrire ou lire des registres pour le flux de données Kinesis. Vous devez utiliser ce paramètre lorsque vous accédez à un flux de données dans un autre compte. Utilisez conjointement avec "awsSTSSessionName".
- "awsSTSSessionName" : (facultatif) utilisé pour la lecture/l'écriture. Un identifiant de la séance assumant le rôle à l'aide d' AWS STS. Vous devez utiliser ce paramètre lorsque vous accédez à un flux de données dans un autre compte. Utilisez conjointement avec "awsSTSRoleARN".

- `"awsSTSEndpoint"`: (Facultatif) Le AWS STS point de terminaison à utiliser lors de la connexion à Kinesis avec un rôle assumé. Cela permet d'utiliser le point de AWS STS terminaison régional dans un VPC, ce qui n'est pas possible avec le point de terminaison global par défaut.
- `"maxFetchTimeInMs"` : (facultatif) utilisé pour la lecture. Durée maximale pendant laquelle l'exécuteur de tâches lit les enregistrements du lot en cours à partir du flux de données Kinesis, spécifiée en millisecondes (ms). Plusieurs appels `GetRecords` d'API peuvent être effectués pendant cette période. La valeur par défaut est `1000`.
- `"maxFetchRecordsPerShard"` : (facultatif) utilisé pour la lecture. Le nombre maximum d'enregistrements à récupérer par partition dans le flux de données Kinesis par microbatch. Remarque : le client peut dépasser cette limite si la tâche de streaming a déjà lu des enregistrements supplémentaires provenant de Kinesis (lors du même appel `get-records`). Si elle `maxFetchRecordsPerShard` doit être stricte, elle doit être un multiple de `maxRecordPerRead`. La valeur par défaut est `100000`.
- `"maxRecordPerRead"` : (facultatif) utilisé pour la lecture. Nombre maximal d'enregistrements à extraire du flux de données Kinesis dans chaque opération `getRecords`. La valeur par défaut est `10000`.
- `"addIdleTimeBetweenReads"` : (facultatif) utilisé pour la lecture. Ajoute un délai entre deux opérations `getRecords` consécutives. La valeur par défaut est `"False"`. Cette option n'est configurable que pour Glue version 2.0 et ultérieure.
- `"idleTimeBetweenReadsInMs"` : (facultatif) utilisé pour la lecture. Délai minimum entre deux opérations `getRecords`, en ms. La valeur par défaut est `1000`. Cette option n'est configurable que pour Glue version 2.0 et ultérieure.
- `"describeShardInterval"` : (facultatif) utilisé pour la lecture. Intervalle de temps minimum entre deux appels d'API `ListShards` pour que votre script envisage le repartitionnement. Pour plus d'informations, consultez [Politiques de repartitionnement](#) dans le Guide du développeur Amazon Kinesis Data Streams. La valeur par défaut est `1s`.
- `"numRetries"` : (facultatif) utilisé pour la lecture. Le nombre maximal de nouvelles tentatives pour les demandes d'API Kinesis Data Streams. La valeur par défaut est `3`.
- `"retryIntervalMs"` : (facultatif) utilisé pour la lecture. Le délai de réflexion (spécifié en ms) avant de réessayer l'appel d'API Kinesis Data Streams. La valeur par défaut est `1000`.
- `"maxRetryIntervalMs"` : (facultatif) utilisé pour la lecture. Le délai d'attente maximal (spécifié en ms) entre deux tentatives d'appel d'API Kinesis Data Streams. La valeur par défaut est `10000`.

- "avoidEmptyBatches" : (facultatif) utilisé pour la lecture. Évite de créer une tâche de micro-lot vide en vérifiant les données non lues dans le flux de données Kinesis avant le démarrage du lot. La valeur par défaut est "False".
- "schema" : (obligatoire lorsque inferSchema est défini sur false) utilisé pour la lecture. Schéma à utiliser pour traiter la charge utile. Si la classification est avro, le schéma fourni doit être au format de schéma Avro. Si la classification n'est pas avro, le schéma fourni doit être au format de schéma DDL.

Voici quelques exemples de schémas.

Exemple in DDL schema format

```
`column1` INT, `column2` STRING , `column3` FLOAT
```

Exemple in Avro schema format

```
{
  "type": "array",
  "items":
  {
    "type": "record",
    "name": "test",
    "fields":
    [
      {
        "name": "_id",
        "type": "string"
      },
      {
        "name": "index",
        "type":
        [
          "int",
          "string",
          "float"
        ]
      }
    ]
  }
}
```

- "inferSchema" : (facultatif) utilisé pour la lecture. La valeur par défaut est « false ». S'il est défini sur « true », le schéma sera détecté lors de l'exécution à partir de la charge utile dans foreachbatch.
- "avroSchema" : (obsolète) utilisé pour la lecture. Paramètre utilisé pour spécifier un schéma de données Avro lorsque le format Avro est utilisé. Ce paramètre est désormais obsolète. Utilisez le paramètre schema.
- "addRecordTimestamp" : (facultatif) utilisé pour la lecture. Lorsque cette option est définie sur « true », la sortie de données contient une colonne supplémentaire nommée « __src_timestamp » qui indique l'heure à laquelle l'enregistrement correspondant est reçu par le flux. La valeur par défaut est « false ». Cette option est prise en charge dans AWS Glue version 4.0 ou ultérieure.
- "emitConsumerLagMetrics" : (facultatif) utilisé pour la lecture. Lorsque l'option est définie sur « vrai », pour chaque lot, elle émet les métriques correspondant à la durée comprise entre le plus ancien enregistrement reçu par le flux et l'heure à laquelle il arrive AWS Glue à CloudWatch. Le nom de la métrique est « glue.driver.streaming ». maxConsumerLagInMs». La valeur par défaut est « false ». Cette option est prise en charge dans AWS Glue version 4.0 ou ultérieure.
- "fanoutConsumerARN" : (facultatif) utilisé pour la lecture. ARN d'un consommateur de flux Kinesis pour le flux spécifié dans streamARN. Utilisé pour activer le mode diffusion améliorée pour votre connexion Kinesis. Pour plus d'informations sur la consommation d'un flux Kinesis avec diffusion améliorée, consultez [the section called "Utilisation de la diffusion améliorée dans les tâches de streaming Kinesis"](#).
- "recordMaxBufferedTime" : (facultatif) utilisé pour l'écriture. Par défaut : 1 000 (ms). Durée maximale pendant laquelle un enregistrement est mis en mémoire tampon en attendant d'être écrit.
- "aggregationEnabled" : (facultatif) utilisé pour l'écriture. Valeur par défaut : vraie. Spécifie si les enregistrements doivent être agrégés avant de les envoyer à Kinesis.
- "aggregationMaxSize" : (facultatif) utilisé pour l'écriture. Par défaut : 51 200 (octets). Si un enregistrement est supérieur à cette limite, il contourne l'agrégateur. Remarque Kinesis impose une limite de 50 Ko à la taille des enregistrements. Si vous définissez ce paramètre au-delà de 50 Ko, les enregistrements surdimensionnés seront rejetés par Kinesis.
- "aggregationMaxCount" : (facultatif) utilisé pour l'écriture. Par défaut : 4294967295. Nombre maximum de résultats à regrouper dans un enregistrement agrégé.
- "producerRateLimit" : (facultatif) utilisé pour l'écriture. Par défaut : 150 (%). Limite le débit par partition envoyée par un seul producteur (votre tâche, par exemple), sous forme de pourcentage de la limite du backend.

- "collectionMaxCount" : (facultatif) utilisé pour l'écriture. Par défaut : 500. Nombre maximum d'articles à inclure dans une PutRecords demande.
- "collectionMaxSize" : (facultatif) utilisé pour l'écriture. Par défaut : 5242880 (octets). Quantité maximale de données à envoyer avec une PutRecords demande.

Utilisation de la diffusion améliorée dans les tâches de streaming Kinesis

Un client bénéficiant de la diffusion améliorée est capable de recevoir des enregistrements provenant d'un flux Kinesis avec un débit dédié qui peut être supérieur à celui des consommateurs classiques. Cela se fait en optimisant le protocole de transfert utilisé pour fournir des données à un client Kinesis, tel que votre tâche. Pour plus d'informations sur la diffusion améliorée de Kinesis, consultez la [documentation Kinesis](#).

En mode de diffusion améliorée, les options de connexion `maxRecordPerRead` et `idleTimeBetweenReadsInMs` ne s'appliquent plus, car ces paramètres ne sont pas configurables lors de la diffusion améliorée. Les options de configuration pour les nouvelles tentatives fonctionnent comme décrit.

Utilisez les procédures suivantes pour activer et désactiver la diffusion améliorée pour votre tâche de streaming. Vous devez enregistrer un consommateur de flux pour chaque tâche qui consommera des données de votre flux.

Pour activer la consommation de diffusion améliorée sur votre tâche :

1. Enregistrez un consommateur de flux pour votre tâche à l'aide de l'API Kinesis. Suivez les instructions de la [documentation Kinesis](#) pour enregistrer un consommateur avec une diffusion améliorée en utilisant à l'aide de l'API Kinesis Data Streams. Il vous suffira de suivre la première étape : appeler [RegisterStreamConsumer](#). Votre demande doit renvoyer un ARN, `consumerARN`.
2. Définissez l'option de connexion `fanoutConsumerARN` sur `consumerARN` dans les arguments de votre méthode de connexion.
3. Redémarrez votre tâche.

Pour désactiver la consommation de diffusion améliorée sur votre tâche :

1. Supprimez l'option de connexion `fanoutConsumerARN` de votre appel de méthode.
2. Redémarrez votre tâche.

3. Suivez les instructions de la [documentation Kinesis](#) pour annuler l'enregistrement d'un consommateur. Ces instructions s'appliquent à la console, mais peuvent également être obtenues via l'API Kinesis. Pour plus d'informations sur la désinscription des utilisateurs de streaming via l'API Kinesis, consultez la documentation Kinesis. [DeregisterStreamConsumer](#)

Connexions Amazon S3

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire des fichiers dans Amazon S3. AWS Glue for Spark prend en charge de nombreux formats de données courants stockés dans Amazon S3 prêts à l'emploi, notamment CSV, Avro, JSON, Orc et Parquet. Pour de plus amples informations sur les formats de données pris en charge, consultez [the section called “Options de format de données”](#). Chaque format de données peut prendre en charge un ensemble différent de fonctionnalités de AWS Glue. Consultez la page de votre format de données pour connaître les spécificités de la prise en charge des fonctionnalités. En outre, vous pouvez lire et écrire des fichiers versionnés stockés dans les cadres de lacs de données Hudi, Iceberg et Delta Lake. Pour plus d'informations sur les cadres de lac de données, consultez [the section called “Cadres de lac de données”](#).

Avec AWS Glue, vous pouvez partitionner vos objets Amazon S3 dans une structure de dossiers pendant l'écriture, puis les récupérer par partition pour améliorer les performances grâce à une configuration simple. Vous pouvez également définir la configuration pour regrouper les petits fichiers lors de la transformation de vos données afin d'améliorer les performances. Vous pouvez lire et écrire des archives bzip2 et gzip dans Amazon S3.

Rubriques

- [Configuration de connexions S3](#)
- [Référence des options de connexion Amazon S3](#)
- [Syntaxes de connexion obsolètes pour les formats de données](#)
- [Exclusion des classes de stockage Amazon S3](#)
- [Gestion des partitions pour la sortie ETL dans AWS Glue](#)
- [Lecture des fichiers en entrée dans des groupes de plus grande taille](#)
- [Types de points de terminaison d'un VPC pour Amazon S3](#)

Configuration de connexions S3

Pour vous connecter à Amazon S3 dans le cadre d'une tâche AWS Glue with Spark, vous aurez besoin de certaines conditions préalables :

- La tâche AWS Glue doit disposer d'autorisations IAM pour les buckets Amazon S3 concernés.

Dans certains cas, vous devrez configurer des prérequis supplémentaires :

- Lorsque vous configurez un accès intercompte, il convient de mettre en place des contrôles d'accès appropriés sur le compartiment Amazon S3.
- Pour des raisons de sécurité, vous pouvez choisir d'acheminer vos requêtes Amazon S3 via un Amazon VPC. Cette approche peut engendrer des problèmes en matière de bande passante et de disponibilité. Pour de plus amples informations, veuillez consulter [the section called “Types de points de terminaison d'un VPC pour Amazon S3”](#).

Référence des options de connexion Amazon S3

Désigne une connexion à Amazon S3.

Comme Amazon S3 gère des fichiers plutôt que des tables, en plus de spécifier les propriétés de connexion fournies dans ce document, vous devrez indiquer une configuration supplémentaire concernant votre type de fichier. Vous indiquez ces informations par le biais des options de format de données. Pour plus d'informations sur ces options de format, consultez [the section called “Options de format de données”](#). Vous pouvez également spécifier ces informations en les intégrant au catalogue de données AWS Glue.

Pour illustrer la distinction entre les options de connexion et les options de format, considérez comment la méthode [the section called “create_dynamic_frame_from_options”](#) utilise `connection_type`, `connection_options`, `format` et `format_options`. Cette section traite spécifiquement des paramètres fournis à `connection_options`.

Utilisez les options de connexion suivantes avec `"connectionType": "s3"` :

- `"paths"` : (obligatoire) une liste de chemins Amazon S3 à lire.
- `"exclusions"` : (Facultatif) Chaîne contenant une liste JSON des modèles glob de style Unix à exclure. Par exemple, `"[\\\"**\\.pdf\\\"]"` permet d'exclure tous les fichiers PDF. Pour plus d'informations sur la syntaxe globale qui AWS Glue supports, voir [Inclure et exclure des modèles](#).
- `"compressionType"` : ou « `compression` » : (facultatif) spécifie la manière dont les données sont comprimées. Utilisez `"compressionType"` pour les sources Amazon S3 et `"compression"` pour les cibles Amazon S3. Ce n'est généralement pas nécessaire si le fichier de données a une extension standard. Les valeurs possibles sont `"gzip"` et `"bzip2"`). Des formats

de compression supplémentaires peuvent être pris en charge pour des formats spécifiques. Pour connaître les spécificités de la prise en charge des fonctionnalités, consultez la page sur le format des données.

- **"groupFiles"** : (facultatif) le groupement de fichiers est activé par défaut lorsque l'entrée contient plus de 50 000 fichiers. Pour activer le groupement lorsqu'il y a moins de 50 000 fichiers, définissez ce paramètre sur **"inPartition"**. Pour désactiver le groupement lorsqu'il y a plus de 50 000 fichiers, définissez ce paramètre sur **"none"**.
- **"groupSize"** : (Facultatif) Taille du groupe cible, en octets. La valeur par défaut est calculée en fonction de la dimension des données en entrée et de la dimension de votre cluster. Lorsqu'il y a moins de 50 000 fichiers en entrée, **"groupFiles"** doit être défini sur **"inPartition"** pour que cela prenne effet.
- **"recurse"** : (Facultatif) Si ce paramètre est défini sur « true », les fichiers sont lus de manière récursive dans tous les sous-répertoires des chemins spécifiés.
- **"maxBand"** : (facultatif, avancé) cette option permet de contrôler la durée, en millisecondes, au delà de laquelle la liste s3 est susceptible d'être cohérente. Les fichiers dont l'horodatage de modification se situe dans les dernières maxBand millisecondes sont suivis lorsque des JobBookmarks sont utilisés pour prendre en compte une cohérence éventuelle Amazon S3. La plupart des utilisateurs n'ont pas besoin de définir cette option. La valeur par défaut est 900 000 millisecondes, soit 15 minutes.
- **"maxFilesInBand"** : (Facultatif, avancé) Cette option spécifie le nombre maximal de fichiers à enregistrer à partir des dernières maxBand secondes. Si ce nombre est dépassé, les fichiers supplémentaires sont ignorés et traités dans l'exécution de tâche suivante. La plupart des utilisateurs n'ont pas besoin de définir cette option.
- **"isFailFast"** : (Facultatif) Cette option détermine si un AWS Glue La tâche ETL génère des exceptions d'analyse par le lecteur. Si elle est définie sur true, les tâches échouent rapidement si quatre tentatives de la tâche Spark échouent à analyser correctement les données.
- **"catalogPartitionPredicate"** : (facultatif) utilisé pour la lecture. Le contenu d'une clause WHERE SQL. Utilisé lors de la lecture de tables du catalogue de données comportant un très grand nombre de partitions. Récupère les partitions correspondantes à partir des index du catalogue de données. Utilisé avec push_down_predicate, une option sur la méthode [the section called "create_dynamic_frame_from_catalog"](#) (et d'autres méthodes similaires). Pour de plus amples informations, veuillez consulter [the section called "Prédicats de partition de catalogue"](#).
- **"partitionKeys"** : (facultatif) utilisé pour l'écriture. Un tableau de chaînes d'étiquettes de colonnes. AWS Glue partitionnera vos données conformément à cette configuration. Pour de plus amples informations, veuillez consulter [the section called "Écriture des partitions"](#).

- "excludeStorageClasses" : (facultatif) utilisé pour la lecture. Un tableau de chaînes spécifiant les classes de stockage Amazon S3. AWS Glue exclura les objets Amazon S3 en fonction de cette configuration. Pour de plus amples informations, veuillez consulter [the section called "Exclusion des classes de stockage Amazon S3"](#).

Syntaxes de connexion obsolètes pour les formats de données

Certains formats de données sont accessibles à l'aide d'une syntaxe de type de connexion spécifique. Cette syntaxe est obsolète. Nous vous recommandons de spécifier vos formats en utilisant le type de connexion `s3` et les options de format fournies dans [the section called "Options de format de données"](#) à la place.

« `connectionType` » : « `orc` »

Désigne une connexion à des fichiers stockés dans Amazon S3 au format de fichier [Apache Hive Optimized Row Columnar \(ORC\)](#).

Utilisez les options de connexion suivantes avec "connectionType": "orc" :

- `paths` : (obligatoire) une liste de chemins Amazon S3 à lire.
- (Autre option de paires nom-valeur) : Les options supplémentaires, y compris les options de formatage, sont transmises directement à la source de données SparkSQL DataSource.

« `connectionType` » : « `parquet` »

Désigne une connexion aux fichiers stockés dans Amazon S3 au format de fichier [Apache Parquet](#).

Utilisez les options de connexion suivantes avec "connectionType": "parquet" :

- `paths` : (obligatoire) une liste de chemins Amazon S3 à lire.
- (Autre option de paires nom-valeur) : Les options supplémentaires, y compris les options de formatage, sont transmises directement à la source de données SparkSQL DataSource.

Exclusion des classes de stockage Amazon S3

Si tu cours AWS Glue Pour les tâches ETL qui lisent des fichiers ou des partitions depuis Amazon Simple Storage Service (Amazon S3), vous pouvez exclure certains types de classes de stockage Amazon S3.

Les classes de stockage suivantes sont disponibles dans Amazon S3 :

- STANDARD — pour le stockage à usage général des données fréquemment consultées.
- INTELLIGENT_TIERING — pour les données ayant des modèles d'accès inconnus ou variables.
- STANDARD_IA et ONEZONE_IA — pour les données à longue durée de vie, mais consultées moins fréquemment.
- GLACIER, DEEP_ARCHIVE et REDUCED_REDUNDANCY — pour l'archivage à long terme et la conservation numérique.

Pour de plus amples informations, veuillez consulter [Classes de stockage Amazon S3](#) dans le Guide du développeur Amazon S3.

Les exemples de cette section montrent comment exclure les classes de stockage GLACIER et DEEP_ARCHIVE. Ces classes vous permettent de répertorier les fichiers, mais ne vous permettent pas de les lire, sauf s'ils sont restaurés. (Pour de plus amples informations, veuillez consulter [Restauration d'objets archivés](#) dans le Guide du développeur Amazon S3.)

En utilisant des exclusions de classes de stockage, vous pouvez vous assurer que votre AWS Glue les tâches fonctionneront sur des tables comportant des partitions réparties entre ces niveaux de classe de stockage. Sans exclusion, les tâches qui lisent les données de ces niveaux échouent avec l'erreur suivante : `AmazonS3Exception: The operation is not valid for the object's storage class` (`AmazonS3Exception` : l'opération n'est pas valide pour la classe de stockage de l'objet).

Vous pouvez filtrer les classes de stockage Amazon S3 de différentes manières dans AWS Glue.

Rubriques

- [Exclusion des classes de stockage Amazon S3 lors de la création d'une image dynamique](#)
- [Exclusion de classes de stockage Amazon S3 d'une table Data Catalog](#)

Exclusion des classes de stockage Amazon S3 lors de la création d'une image dynamique

Pour exclure les classes de stockage Amazon S3 lors de la création d'un cadre dynamique, utilisez `excludeStorageClasses` in `additionalOptions`. AWS Glue utilise automatiquement sa propre `Lister` implémentation Amazon S3 pour répertorier et exclure les fichiers correspondant aux classes de stockage spécifiées.

Les exemples Python et Scala suivants montrent comment exclure les classes de stockage GLACIER et DEEP_ARCHIVE lors de la création d'une image dynamique.

Exemple Python :

```
glueContext.create_dynamic_frame.from_catalog(  
    database = "my_database",  
    tableName = "my_table_name",  
    redshift_tmp_dir = "",  
    transformation_ctx = "my_transformation_context",  
    additional_options = {  
        "excludeStorageClasses" : ["GLACIER", "DEEP_ARCHIVE"]  
    }  
)
```

Exemple Scala :

```
val* *df = glueContext.getCatalogSource(  
    nameSpace, tableName, "", "my_transformation_context",  
    additionalOptions = JsonOptions(  
        Map("excludeStorageClasses" -> List("GLACIER", "DEEP_ARCHIVE"))  
    )  
)  
.getDynamicFrame()
```

Exclusion de classes de stockage Amazon S3 d'une table Data Catalog

Vous pouvez spécifier les exclusions de classes de stockage à utiliser par un AWS Glue Job ETL en tant que paramètre de table dans le catalogue de données AWS Glue. Vous pouvez inclure ce paramètre dans l'opération `CreateTable` à l'aide du AWS Command Line Interface (AWS CLI) ou par programmation à l'aide de l'API. Pour plus d'informations, voir [Structure du tableau](#) et [CreateTable](#).

Vous pouvez également spécifier les classes de stockage exclues sur AWS Glue console.

Pour exclure des classes de stockage Amazon S3 (console)

1. Connectez-vous au AWS Management Console et ouvrez-le AWS Glue console à <https://console.aws.amazon.com/glue/>.
2. Dans le panneau de navigation de gauche, sélectionnez Tables.
3. Choisissez le nom de la table dans la liste, puis choisissez Modifier la table.
4. Dans Propriétés de la table, ajoutez **excludeStorageClasses** en tant que clé et `["GLACIER", "DEEP_ARCHIVE"]` en tant que valeur.
5. Choisissez Appliquer.

Gestion des partitions pour la sortie ETL dans AWS Glue

Le partitionnement est une technique importante technique pour organiser les ensembles de données afin qu'ils puissent être interrogés de manière efficace. Il organise les données en une structure de répertoires hiérarchique fondée sur les valeurs distinctes d'une ou de plusieurs colonnes.

Par exemple, vous pouvez décider de partitionner vos journaux d'application dans Amazon Simple Storage Service (Amazon S3) par date, réparties par année, par mois et par jour. Les fichiers qui correspondent à une seule journée de données sont ensuite placés sous un préfixe, tel que `s3://my_bucket/logs/year=2018/month=01/day=23/`. Des systèmes tels qu'Amazon Athena, Amazon Redshift Spectrum et maintenant AWS Glue peut utiliser ces partitions pour filtrer les données par valeur de partition sans avoir à lire toutes les données sous-jacentes d'Amazon S3.

Les robots d'exploration ne se contentent pas de déduire les types de fichiers et les schémas, ils identifient également automatiquement la structure de partition de votre ensemble de données lorsqu'ils alimentent le catalogue de données AWS Glue. Les colonnes de partition résultantes peuvent être consultées dans AWS Glue Jobs ETL ou moteurs de requêtes tels qu'Amazon Athena.

Après avoir analysé une table, vous pouvez afficher les partitions créées par l'crawler. Dans le volet AWS Glue console, choisissez Tables dans le volet de navigation de gauche. Sélectionnez la table créée par l'crawler, puis View partitions (Afficher les partitions).

Pour les chemins partitionnés de style Apache Hive de type `key=val`, les crawlers remplissent automatiquement le nom de la colonne à l'aide du nom de clé. Sinon, ils utilisent des noms par défaut comme `partition_0`, `partition_1`, etc. Vous pouvez modifier les noms par défaut sur la console. Pour ce faire, accédez à la table. Vérifiez si des index existent sous l'onglet Index. Si tel est le cas, vous devez les supprimer pour continuer (vous pourrez ensuite les recréer en utilisant les nouveaux noms de colonnes). Choisissez ensuite Modifier le schéma et modifiez les noms des colonnes de partition qui s'y trouvent.

Dans vos scripts ETL, vous pouvez ensuite filtrer sur les colonnes de partition. Étant donné que les informations de partition sont stockées dans le catalogue de données, utilisez les appels d'API `from_catalog` pour inclure les colonnes de partition dans le fichier `DynamicFrame`. Par exemple, utilisez `create_dynamic_frame.from_catalog` plutôt que `create_dynamic_frame.from_options`.

Le partitionnement est une technique d'optimisation qui réduit l'analyse des données. Pour plus d'informations sur le processus permettant d'identifier le moment où cette technique est appropriée, consultez la section [Réduire la quantité de données analysées dans le guide](#) des meilleures

pratiques pour le réglage des performances de AWS Glue pour les tâches Apache Spark sur le guide AWS prescriptif.

Préfiltrage à l'aide des prédicats pushdown

Dans de nombreux cas, vous pouvez utiliser un prédicat pushdown pour filtrer les partitions sans avoir à répertorier et à lire tous les fichiers de votre ensemble de données. Au lieu de lire l'ensemble de données et de filtrer ensuite un DynamicFrame fichier, vous pouvez appliquer le filtre directement sur les métadonnées de partition dans le catalogue de données. Ensuite, vous ne listez et ne lisez que ce dont vous avez réellement besoin dans un DynamicFrame.

Par exemple, en Python, vous pouvez écrire ce qui suit.

```
glue_context.create_dynamic_frame.from_catalog(  
    database = "my_S3_data_set",  
    table_name = "catalog_data_table",  
    push_down_predicate = my_partition_predicate)
```

Cela crée un DynamicFrame qui charge uniquement les partitions du catalogue de données qui répondent à l'expression de prédicat. En fonction de la taille d'un sous-ensemble de vos données de chargement, vous pouvez économiser beaucoup de temps de traitement.

L'expression de prédicat peut être n'importe quelle expression booléenne prise en charge par Spark SQL. Tout ce que vous pouvez placer dans une clause WHERE d'une requête SQL Spark fonctionne. Par exemple, l'expression de prédicat `pushDownPredicate = "(year=='2017' and month=='04')"` charge uniquement les partitions dans Data Catalog qui disposent à la fois d'une year égale à 2017 et un month égal à 04. Pour plus d'informations, consultez la documentation [Apache Spark SQL](#), en particulier le document [Référence des fonctions Scala SQL](#).

Filtrage côté serveur à l'aide de prédicats de partition de catalogue

L'option `push_down_predicate` est appliquée après avoir répertorié toutes les partitions du catalogue et avant de répertorier les fichiers d'Amazon S3 pour ces partitions. Si vous disposez d'un grand nombre de partitions pour une table, la liste des partitions du catalogue peut encore entraîner une surcharge de temps supplémentaire. Pour remédier à cette surcharge, vous pouvez utiliser l'élagage des partitions côté serveur avec l'`catalogPartitionPredicateoption` qui utilise les [index de partition dans](#) le catalogue de données Glue AWS . Cela accélère considérablement le filtrage des partitions lorsque vous avez des millions de partitions dans une table. Vous pouvez utiliser à la fois `push_down_predicate` et `catalogPartitionPredicate` dans

`additional_options` si votre `catalogPartitionPredicate` a besoin d'une syntaxe de prédicat qui n'est pas encore prise en charge avec les index de partition de catalogue.

Python :

```
dynamic_frame = glueContext.create_dynamic_frame.from_catalog(  
    database=dbname,  
    table_name=tablename,  
    transformation_ctx="datasource0",  
    push_down_predicate="day>=10 and customer_id like '10%'",  
    additional_options={"catalogPartitionPredicate":"year='2021' and month='06'"}  
)
```

Scala :

```
val dynamicFrame = glueContext.getCatalogSource(  
    database = dbname,  
    tableName = tablename,  
    transformationContext = "datasource0",  
    pushDownPredicate="day>=10 and customer_id like '10%'",  
    additionalOptions = JsonOptions("""{  
        "catalogPartitionPredicate": "year='2021' and month='06'"}""")  
).getDynamicFrame()
```

Note

`push_down_predicate` et `catalogPartitionPredicate` utilisent des syntaxes différentes. Le premier utilise la syntaxe standard SQL Spark et le dernier utilise l'analyseur JSQL.

Écriture des partitions

Par défaut, un `DynamicFrame` n'est pas partitionné lors de son écriture. Tous les fichiers de sortie sont écrits au niveau supérieur du chemin de sortie spécifié. Jusqu'à récemment, le seul moyen d'écrire un `DynamicFrame` dans des partitions était de le convertir en SQL Spark `DataFrame` avant de l'écrire.

Cependant, vous pouvez désormais `DynamicFrames` prendre en charge le partitionnement natif à l'aide d'une séquence de clés, en utilisant `partitionKeysoption` lorsque vous créez un récepteur.

Par exemple, le code Python suivant écrit un ensemble de données sur Amazon S3 au format Parquet, dans les répertoires partitionnés par le type de champ. À partir de là, vous pouvez traiter ces partitions à l'aide d'autres systèmes, comme Amazon Athena.

```
glue_context.write_dynamic_frame.from_options(  
    frame = projectedEvents,  
    connection_type = "s3",  
    connection_options = {"path": "$outpath", "partitionKeys": ["type"]},  
    format = "parquet")
```

Lecture des fichiers en entrée dans des groupes de plus grande taille

Vous pouvez définir les propriétés de vos tables pour activer une AWS Glue Tâche ETL pour regrouper les fichiers lorsqu'ils sont lus depuis un magasin de données Amazon S3. Ces propriétés permettent à chaque tâche ETL de lire un groupe de fichiers d'entrée en une seule partition en mémoire, ce qui est particulièrement utile lorsqu'il y a un grand nombre de petits fichiers dans votre magasin de données Amazon S3. Lorsque vous définissez certaines propriétés, vous indiquez AWS Glue pour regrouper des fichiers au sein d'une partition de données Amazon S3 et définir la taille des groupes à lire. Vous pouvez également définir ces options lors de la lecture à partir d'un magasin de données Amazon S3 avec la méthode `create_dynamic_frame.from_options`.

Pour activer le regroupement de fichiers pour une table, vous définissez les paires clé-valeur dans le champ des paramètres de la structure de votre table. Utilisez la notation JSON pour définir une valeur pour le champ des paramètres de votre table. Pour plus d'informations sur la modification des propriétés d'une table, consultez [Afficher et gérer les détails des tables](#).

Vous pouvez utiliser cette méthode pour activer le regroupement des tables dans Data Catalog avec les magasins de données Amazon S3.

groupFiles

Définissez `GroupFiles` sur `inPartition` permettre le regroupement de fichiers au sein d'une partition de données Amazon S3. AWS Glue active automatiquement le regroupement s'il existe plus de 50 000 fichiers d'entrée, comme dans l'exemple suivant.

```
'groupFiles': 'inPartition'
```

groupSize

Définissez `groupSize` sur la taille cible des groupes en octets. La propriété `GroupSize` est facultative, si elle n'est pas fournie, AWS Glue calcule une taille pour utiliser tous les cœurs de processeur du cluster tout en réduisant le nombre total de tâches ETL et de partitions en mémoire.

Par exemple, ce qui suit définit une taille de groupe de 1 Mo.

```
'groupSize': '1048576'
```

Notez que le `groupsize` doit être défini avec le résultat d'un calcul. Par exemple, $1024 * 1024 = 1048576$.

recurse

Définissez `recurse` (récursif) à `True` pour lire les fichiers de manière récursive dans tous les sous-répertoires lorsque vous spécifiez `paths` en tant que liste de chemins. Vous n'avez pas besoin de définir `recurse` si `paths` est un tableau de clés d'objet dans Amazon S3, ou si le format d'entrée est `parquet/orc`, comme dans l'exemple suivant.

```
'recurse':True
```

Si vous lisez à partir d'Amazon S3 directement à l'aide de la méthode `create_dynamic_frame.from_options`, ajoutez ces options de connexion. Par exemple, ce qui suit tente de placer les fichiers par groupes de 1 Mo.

```
df = glueContext.create_dynamic_frame.from_options("s3", {'paths': ["s3://s3path/"],  
'recurse':True, 'groupFiles': 'inPartition', 'groupSize': '1048576'}, format="json")
```

 Note

`groupFile` est pris en charge pour les formats de données `DynamicFrames` créés à partir des formats de données suivants : `csv`, `ion`, `GrokLog`, `json` et `xml`. Cette option n'est pas prise en charge pour `avro`, `parquet` et `orc`.

Types de points de terminaison d'un VPC pour Amazon S3

Pour des raisons de sécurité, de nombreux AWS clients exécutent leurs applications dans un environnement Amazon Virtual Private Cloud (Amazon VPC). Avec Amazon VPC, vous pouvez lancer des EC2 instances Amazon dans un cloud privé virtuel, qui est logiquement isolé des autres réseaux, y compris de l'Internet public. Avec un VPC Amazon, vous contrôlez sa plage d'adresses IP, ses sous-réseaux, ses tables de routage, ses passerelles réseau et ses paramètres de sécurité.

 Note

Si vous avez créé votre AWS compte après le 04/12/2013, vous disposez déjà d'un VPC par défaut dans chaque région. AWS Vous pouvez commencer immédiatement à utiliser votre VPC par défaut sans configuration supplémentaire.

Pour plus d'informations, veuillez consulter [Vos VPC et sous-réseaux par défaut](#) dans le Guide de l'utilisateur Amazon VPC.


De nombreux clients ont des préoccupations légitimes liées à la confidentialité et la sécurité lors de l'envoi et de la réception de données via le réseau Internet public. Les clients peuvent faire face à ces préoccupations en utilisant un réseau VPN pour acheminer l'ensemble du trafic réseau d'Amazon S3 via leur propre infrastructure réseau d'entreprise. Toutefois, cette approche peut engendrer des problèmes en matière de bande passante et de disponibilité.

Les points de terminaison d'un VPC pour Amazon S3 peuvent atténuer ces problèmes. Un point de terminaison VPC pour Amazon S3 permet AWS Glue d'utiliser des adresses IP privées pour accéder à Amazon S3 sans aucune exposition à l'Internet public. AWS Glue ne nécessite pas d'adresses IP publiques et vous n'avez pas besoin d'une passerelle Internet, d'un périphérique NAT ou d'une passerelle privée virtuelle dans votre VPC. Vous utilisez des politiques de point de terminaison pour contrôler l'accès à Amazon S3. Le trafic entre votre VPC et le AWS service ne quitte pas le réseau Amazon.

Lorsque vous créez un point de terminaison d'un VPC pour Amazon S3, toutes les demandes envoyées à un point de terminaison Amazon S3 au sein de la région (par exemple, s3.us-west-2.amazonaws.com) sont acheminées vers un point de terminaison Amazon S3 privé dans le réseau Amazon. Vous n'avez pas besoin de modifier vos applications exécutées sur les EC2 instances Amazon de votre VPC : le nom du point de terminaison reste le même, mais le chemin vers Amazon S3 reste entièrement au sein du réseau Amazon et n'accède pas à l'Internet public.

Pour plus d'informations sur les points de terminaison d'un VPC, veuillez consulter [Points de terminaison d'un VPC](#) dans le Guide de l'utilisateur Amazon VPC.

Le schéma suivant montre comment AWS Glue peut utiliser un point de terminaison VPC pour accéder à Amazon S3.



Pour configurer l'accès à Amazon S3

1. Connectez-vous à la console Amazon VPC AWS Management Console et ouvrez-la à l'adresse.
<https://console.aws.amazon.com/vpc/>
2. Dans le panneau de navigation de gauche, sélectionnez Points de terminaison.
3. Sélectionnez Create Endpoint (Créer un point de terminaison) et suivez les étapes pour créer un point de terminaison d'un VPC Amazon S3 de type Passerelle.

Connexions Amazon DocumentDB

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire dans des tables d'Amazon DocumentDB. Vous pouvez vous connecter à Amazon DocumentDB à l'aide des informations d'identification enregistrées AWS Secrets Manager via une connexion AWS Glue.

Pour plus d'informations sur Amazon DocumentDB, consultez la [documentation Amazon DocumentDB](#).

Note

Les clusters élastiques Amazon DocumentDB ne sont actuellement pas pris en charge lors de l'utilisation du connecteur AWS Glue. Pour plus d'informations sur les clusters élastiques, consultez [Using Amazon DocumentDB elastic clusters](#).

Lecture et écriture dans les collections Amazon DocumentDB

Note

Lorsque vous créez une tâche ETL qui se connecte à Amazon DocumentDB pour la propriété de tâche `Connections`, vous devez désigner un objet de connexion qui spécifie le virtual private cloud (VPC) dans lequel Amazon DocumentDB est exécuté. Pour l'objet de connexion, le type de connexion doit être JDBC et le JDBC URL doit être `mongo://<DocumentDB_host>:27017`.

Note

Ces exemples de code ont été développés pour AWS Glue 3.0. Pour migrer vers AWS Glue 4.0, consultez [the section called “MongoDB”](#). Le paramètre `uri` a été modifié.

Note

Lorsque vous utilisez Amazon DocumentDB, le paramètre `retryWrites` doit être défini sur `false` dans certaines situations, par exemple lorsque le document écrit spécifie `_id`. Pour plus d'informations, consultez [Différences fonctionnelles avec MongoDB](#) dans la documentation Amazon DocumentDB.

Le script Python suivant illustre l'utilisation des types et des options de connexion pour la lecture et l'écriture dans Amazon DocumentDB.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext, SparkConf
from awsglue.context import GlueContext
from awsglue.job import Job
import time

## @params: [JOB_NAME]
args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

job = Job(glueContext)
job.init(args['JOB_NAME'], args)

output_path = "s3://some_bucket/output/" + str(time.time()) + "/"
documentdb_uri = "mongodb://<mongo-instanced-ip-address>:27017"
documentdb_write_uri = "mongodb://<mongo-instanced-ip-address>:27017"

read_docdb_options = {
    "uri": documentdb_uri,
```

```

    "database": "test",
    "collection": "coll",
    "username": "username",
    "password": "1234567890",
    "ssl": "true",
    "ssl.domain_match": "false",
    "partitioner": "MongoSamplePartitioner",
    "partitionerOptions.partitionSizeMB": "10",
    "partitionerOptions.partitionKey": "_id"
  }

write_documentdb_options = {
  "retryWrites": "false",
  "uri": documentdb_write_uri,
  "database": "test",
  "collection": "coll",
  "username": "username",
  "password": "pwd"
}

# Get DynamicFrame from DocumentDB
dynamic_frame2 =
  glueContext.create_dynamic_frame.from_options(connection_type="documentdb",

  connection_options=read_docdb_options)

# Write DynamicFrame to MongoDB and DocumentDB
glueContext.write_dynamic_frame.from_options(dynamic_frame2,
  connection_type="documentdb",

  connection_options=write_documentdb_options)

job.commit()

```

Le script Scala suivant illustre l'utilisation des types et des options de connexion pour la lecture et l'écriture dans Amazon DocumentDB.

```

import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions

```

```

import com.amazonaws.services.glue.DynamicFrame
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {
  val DOC_URI: String = "mongodb://<mongo-instanced-ip-address>:27017"
  val DOC_WRITE_URI: String = "mongodb://<mongo-instanced-ip-address>:27017"
  lazy val documentDBJsonOption = jsonOptions(DOC_URI)
  lazy val writeDocumentDBJsonOption = jsonOptions(DOC_WRITE_URI)
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    // Get DynamicFrame from DocumentDB
    val resultFrame2: DynamicFrame = glueContext.getSource("documentdb",
documentDBJsonOption).getDynamicFrame()

    // Write DynamicFrame to DocumentDB
    glueContext.getSink("documentdb", writeJsonOption).writeDynamicFrame(resultFrame2)

    Job.commit()
  }

  private def jsonOptions(uri: String): JsonOptions = {
    new JsonOptions(
      s"""{"uri": "${uri}",
        |"database": "test",
        |"collection": "coll",
        |"username": "username",
        |"password": "pwd",
        |"ssl": "true",
        |"ssl.domain_match": "false",
        |"partitioner": "MongoSamplePartitioner",
        |"partitionerOptions.partitionSizeMB": "10",
        |"partitionerOptions.partitionKey": "_id"}""".stripMargin)
  }
}

```

Référence des options de connexion Amazon DocumentDB

Désigne une connexion à Amazon DocumentDB (compatible avec MongoDB).

Les options de connexion sont différentes pour une connexion source et une connexion collecteur.

« `connectionType` »: « `documentdb` » comme source

Utilisez les options de connexion suivantes avec "`connectionType`": "`documentdb`" comme source :

- "`uri`" : (obligatoire) hôte Amazon DocumentDB à lire, dans le format `mongodb://<host>:<port>`.
- "`database`" : (obligatoire) base de données Amazon DocumentDB à lire.
- "`collection`" : (obligatoire) collection Amazon DocumentDB à lire.
- "`username`" : (obligatoire) nom d'utilisateur Amazon DocumentDB.
- "`password`" : (obligatoire) mot de passe Amazon DocumentDB.
- "`ssl`" : (obligatoire si vous utilisez SSL) si votre connexion utilise SSL, vous devez inclure cette option avec la valeur "`true`".
- "`ssl.domain_match`" : (obligatoire si vous utilisez SSL) si votre connexion utilise SSL, vous devez inclure cette option avec la valeur "`false`".
- "`batchSize`" : (Facultatif) : Nombre de documents à renvoyer par lot, utilisé dans le curseur des lots internes.
- "`partitioner`" : (facultatif) : nom de classe de l'outil du partitionneur pour lire les données d'entrée à partir d'Amazon DocumentDB. Le connecteur fournit les partitionneurs suivants :
 - `MongoDefaultPartitioner`(par défaut) (Non pris en charge dans AWS Glue 4.0)
 - `MongoSamplePartitioner`(Non pris en charge dans AWS Glue 4.0)
 - `MongoShardedPartitioner`
 - `MongoSplitVectorPartitioner`
 - `MongoPaginateByCountPartitioner`
 - `MongoPaginateBySizePartitioner`(Non pris en charge dans AWS Glue 4.0)
- "`partitionerOptions`" (Facultatif) : Options pour le partitionneur désigné. Les options suivantes sont prises en charge pour chaque partitionneur :
 - `MongoSamplePartitioner`: `partitionKey`, `partitionSizeMB`, `samplesPerPartition`
 - `MongoShardedPartitioner`: `shardkey`
 - `MongoSplitVectorPartitioner`: `partitionKey`, `partitionSizeMB`
 - `MongoPaginateByCountPartitioner`: `partitionKey`, `numberOfPartitions`

- `MongoPaginateBySizePartitioner` : `partitionKey`, `partitionSizeMB`

Pour plus d'informations sur ces options, consultez [Configuration du partitionneur](#) dans la documentation MongoDB.

« `connectionType` »: « `documentdb` » comme collecteur

Utilisez les options de connexion suivantes avec `"connectionType": "documentdb"` comme collecteur :

- `"uri"` : (obligatoire) hôte Amazon DocumentDB où écrire, dans le format `mongodb://<host>:<port>`.
- `"database"` : (obligatoire) base de données Amazon DocumentDB où écrire.
- `"collection"` : (obligatoire) collection Amazon DocumentDB où écrire.
- `"username"` : (obligatoire) nom d'utilisateur Amazon DocumentDB.
- `"password"` : (obligatoire) mot de passe Amazon DocumentDB.
- `"extendedBsonTypes"` : (facultatif) si la valeur est `true`, cela autorise les types BSON étendus lors de l'écriture de données dans Amazon DocumentDB. L'argument par défaut est `true`.
- `"replaceDocument"` : (Facultatif) Si `true`, remplace l'ensemble du document lors de l'enregistrement de jeux de données contenant un champ `_id`. Si `false`, seuls les champs du document qui correspondent aux champs du jeu de données sont mis à jour. L'argument par défaut est `true`.
- `"maxBatchSize"` : (Facultatif) : Taille maximale du lot pour les opérations en bloc lors de l'enregistrement des données. La valeur par défaut est 512.
- `"retryWrites"`: (Facultatif) : Réessayez automatiquement certaines opérations d'écriture une seule fois si AWS Glue rencontre une erreur réseau.

OpenSearch Connexions de service

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire dans des tables dans OpenSearch Service in AWS Glue 4.0 et versions ultérieures. Vous pouvez définir ce qu'il faut lire dans OpenSearch Service à l'aide d'une OpenSearch requête. Vous vous connectez au OpenSearch Service à l'aide des informations d'authentification HTTP de base stockées AWS Secrets Manager via une connexion AWS Glue. Cette fonctionnalité n'est pas compatible avec le OpenSearch Service serverless.

Pour plus d'informations sur Amazon OpenSearch Service, consultez la [documentation Amazon OpenSearch Service](#).

Configuration des connexions OpenSearch de service

Pour vous connecter à OpenSearch Service from AWS Glue, vous devez créer et stocker vos identifiants de OpenSearch service dans un AWS Secrets Manager secret, puis associer ce secret à une connexion OpenSearch Service AWS Glue.

Prérequis :

- Identifiez le point de terminaison *aosEndpoint* et le port du domaine que *aosPort* vous souhaitez consulter, ou créez la ressource en suivant les instructions de la documentation Amazon OpenSearch Service. Pour plus d'informations sur la création d'un domaine, consultez [la section Création et gestion OpenSearch de domaines Amazon Service](#) dans la documentation Amazon OpenSearch Service.

Un point de terminaison de domaine Amazon OpenSearch Service aura le formulaire par défaut suivant, `https://search - domainName -unstructuredIdContent. region.es.amazonaws.com`. Pour plus d'informations sur l'identification du point de terminaison de votre domaine, consultez la section [Création et gestion des domaines Amazon OpenSearch Service](#) dans la documentation Amazon OpenSearch Service.

Identifiez ou générez des informations d'authentification HTTP de base, *aosUser* et *aosPassword* pour votre domaine.

Pour configurer une connexion au OpenSearch service :

- Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification OpenSearch de service. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé USERNAME contenant la valeur. *aosUser*
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé PASSWORD contenant la valeur. *aosPassword*

2. Dans la console AWS Glue, créez une connexion en suivant les étapes décrites dans [the section called “Ajouter une AWS Glue connexion”](#). Après avoir créé la connexion, conservez le nom de la connexion pour une utilisation future dans AWS Glue. *connectionName*

- Lorsque vous sélectionnez un type de connexion, sélectionnez OpenSearch Service.
- Lorsque vous sélectionnez un point de terminaison de domaine, fournissez *aosEndpoint*.
- Lorsque vous sélectionnez un port, indiquez *aosPort*.
- Lorsque vous sélectionnez un AWS secret, fournissez *secretName*.

Après avoir créé une connexion AWS Glue OpenSearch Service, vous devez suivre les étapes suivantes avant d'exécuter votre tâche AWS Glue :

- Accordez au rôle IAM associé à votre tâche AWS Glue l'autorisation de lire *secretName*.
- Dans la configuration de votre tâche AWS Glue *connectionName*, fournissez une connexion réseau supplémentaire.

Lecture à partir des index OpenSearch de service

Prérequis :

- Un index des OpenSearch services que vous aimeriez lire, *aosIndex*.
- Une connexion AWS Glue OpenSearch Service configurée pour fournir des informations d'authentification et de localisation réseau. Pour cela, suivez les étapes de la procédure précédente, Pour configurer une connexion au OpenSearch service. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.

Cet exemple lit un index provenant d'Amazon OpenSearch Service. Vous devrez fournir le paramètre pushdown.

Par exemple :

```
opensearch_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="opensearch",  
    connection_options={  
        "connectionName": "connectionName",  
        "opensearch.resource": "aosIndex",  
        "pushdown": "true",  
    }  
)
```

```
)
```

Vous pouvez également fournir une chaîne de requête pour filtrer les résultats renvoyés dans votre `DynamicFrame`. Vous devrez configurer `opensearch.query`.

`opensearch.query` peut prendre une chaîne de paramètres de requête URL *queryString* ou un objet *queryObject* JSON DSL de requête. Pour plus d'informations sur la requête DSL, consultez la section [Requête DSL](#) dans la OpenSearch documentation. Pour fournir une chaîne de paramètres de requête URL, ajoutez `?q=` à votre requête, comme vous le feriez pour une URL complète. Pour fournir un objet de requête DSL, échapper une chaîne objet JSON avant de le fournir.

Par exemple :

```

        queryObject = "{ \"query\": { \"multi_match\": { \"query\": \"Sample\", \"fields\":
[ \"sample\" ] } } }"
        queryString = "?q=queryString"

        opensearch_read_query = glueContext.create_dynamic_frame.from_options(
            connection_type="opensearch",
            connection_options={
                "connectionName": "connectionName",
                "opensearch.resource": "aosIndex",
                "opensearch.query": queryString,
                "pushdown": "true",
            }
        )

```

Pour plus d'informations sur la façon de créer une requête en dehors de sa syntaxe spécifique, consultez la section [Syntaxe des chaînes de requête](#) dans la OpenSearch documentation.

Lorsque vous lisez des OpenSearch collections contenant des données de type tableau, vous devez spécifier quels champs sont de type tableau dans votre appel de méthode à l'aide du `opensearch.read.field.as.array.include` paramètre.

Par exemple, en lisant le document suivant, vous rencontrerez les champs `genre` et `actor` du tableau :

```

{
  "_index": "movies",
  "_id": "2",

```

```
{
  "_version": 1,
  "_seq_no": 0,
  "_primary_term": 1,
  "found": true,
  "_source": {
    "director": "Frankenheimer, John",
    "genre": [
      "Drama",
      "Mystery",
      "Thriller",
      "Crime"
    ],
    "year": 1962,
    "actor": [
      "Lansbury, Angela",
      "Sinatra, Frank",
      "Leigh, Janet",
      "Harvey, Laurence",
      "Silva, Henry",
      "Frees, Paul",
      "Gregory, James",
      "Bissell, Whit",
      "McGiver, John",
      "Parrish, Leslie",
      "Edwards, James",
      "Flowers, Bess",
      "Dhiegh, Khigh",
      "Payne, Julie",
      "Kleeb, Helen",
      "Gray, Joe",
      "Nalder, Reggie",
      "Stevens, Bert",
      "Masters, Michael",
      "Lowell, Tom"
    ],
    "title": "The Manchurian Candidate"
  }
}
```

Dans ce cas, vous devez inclure les noms de ces champs dans votre appel de méthode. Par exemple :

```
"opensearch.read.field.as.array.include": "genre,actor"
```

Si votre champ de tableau est imbriqué dans la structure de votre document, faites-y référence en utilisant la notation par points : "genre, actor, foo.bar.baz". Cela permet de spécifier un tableau baz inclus dans votre document source par le biais du document intégré foo contenant le document intégré bar.

Écrire dans les tables OpenSearch de service

Cet exemple écrit les informations d'un fichier existant DynamicFrame *dynamicFrame* dans le OpenSearch Service. Si l'index contient déjà des informations, AWS Glue ajoutera les données de votre DynamicFrame. Vous devrez fournir le paramètre pushdown.

Prérequis :

- Une table de OpenSearch service à laquelle vous souhaitez écrire. Vous aurez besoin des informations d'identification de la table. Appelons ça *tableName*.
- Une connexion AWS Glue OpenSearch Service configurée pour fournir des informations d'authentification et de localisation réseau. Pour cela, suivez les étapes de la procédure précédente, Pour configurer une connexion au OpenSearch service. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.

Par exemple :

```
glueContext.write_dynamic_frame.from_options(  
    frame=dynamicFrame,  
    connection_type="opensearch",  
    connection_options={  
        "connectionName": "connectionName",  
        "opensearch.resource": "aosIndex",  
    },  
)
```

OpenSearch Référence des options de connexion au service

- `connectionName` — Obligatoire. Utilisé pour la lecture/l'écriture. Nom d'une connexion AWS Glue OpenSearch Service configurée pour fournir des informations d'authentification et de localisation réseau à votre méthode de connexion.
- `opensearch.resource` — Obligatoire. Utilisé pour la lecture/l'écriture. Valeurs valides : noms d'OpenSearch index. Le nom de l'index avec lequel votre méthode de connexion va interagir.

- `opensearch.query` : utilisé pour la lecture. Valeurs valides : chaîne JSON échappée ou, lorsque cette chaîne commence par `?`, la partie de recherche d'une URL. Une OpenSearch requête qui filtre ce qui doit être récupéré lors de la lecture. Pour plus d'informations sur l'utilisation de ce paramètre, consultez la section précédente [the section called “Lire depuis le OpenSearch service”](#).
- `pushdown` — Obligatoire si. Utilisé pour la lecture. Valeurs valides : booléen. Demande à Spark de transmettre les requêtes de lecture OpenSearch afin que la base de données ne renvoie que les documents pertinents.
- `opensearch.read.field.as.array.include` : obligatoire en cas de lecture de données de type tableau. Utilisé pour la lecture. Valeurs valides : listes de noms de champs séparés par des virgules. Spécifie les champs à lire sous forme de tableaux à partir de OpenSearch documents. Pour plus d'informations sur l'utilisation de ce paramètre, consultez la section précédente [the section called “Lire depuis le OpenSearch service”](#).

Connexions Redshift

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire dans les tables des bases de données Amazon Redshift. Lors de la connexion aux bases de données Amazon Redshift, AWS Glue déplace les données via Amazon S3 pour atteindre un débit maximal, en utilisant le code SQL et les commandes Amazon Redshift. `COPY UNLOAD` Dans AWS Glue 4.0 et versions ultérieures, vous pouvez utiliser [l'intégration Amazon Redshift pour Apache Spark pour](#) lire et écrire avec des optimisations et des fonctionnalités spécifiques à Amazon Redshift, au-delà de celles disponibles lors de la connexion via les versions précédentes.

Découvrez comment AWS Glue facilite plus que jamais la migration des utilisateurs d'Amazon Redshift vers AWS Glue pour l'intégration des données sans serveur et l'ETL.

Configuration des connexions Redshift

Pour utiliser les clusters Amazon Redshift dans AWS Glue, vous devez remplir certaines conditions préalables :

- Un répertoire Amazon S3 à utiliser pour le stockage temporaire lors de la lecture et de l'écriture dans la base de données.
- Un Amazon VPC permettant la communication entre votre cluster Amazon Redshift, votre tâche AWS Glue et votre répertoire Amazon S3.
- Autorisations IAM appropriées sur le job AWS Glue et le cluster Amazon Redshift.

Configuration des rôles IAM

Configurer le rôle pour le cluster Amazon Redshift

Votre cluster Amazon Redshift doit être capable de lire et d'écrire sur Amazon S3 pour pouvoir s'intégrer aux tâches AWS Glue. Pour autoriser cela, vous pouvez associer des rôles IAM au cluster Amazon Redshift auquel vous souhaitez vous connecter. Votre rôle doit disposer d'une politique autorisant la lecture et l'écriture dans votre répertoire temporaire Amazon S3. Votre rôle doit avoir une relation de confiance permettant au service `redshift.amazonaws.com` de `AssumeRole`.

Pour associer un rôle IAM à Amazon Redshift


1. Conditions préalables : un compartiment ou un répertoire Amazon S3 utilisé pour le stockage temporaire de fichiers.
2. Identifiez les autorisations Amazon S3 dont votre cluster Amazon Redshift aura besoin. Lors du déplacement de données vers et depuis un cluster Amazon Redshift, les tâches AWS Glue émettent des instructions COPY et UNLOAD à l'encontre d'Amazon Redshift. Si votre tâche modifie une table dans Amazon Redshift, AWS Glue émettra également des instructions CREATE LIBRARY. Pour plus d'informations sur les autorisations Amazon S3 spécifiques requises pour qu'Amazon Redshift exécute ces instructions, consultez la documentation Amazon Redshift : [Amazon Redshift : Permissions to access other Resources](#). AWS
3. Dans la console IAM, créez une politique IAM avec les autorisations nécessaires. Pour plus d'informations sur la création de politiques, consultez [Création de politiques IAM](#).
4. Dans la console IAM, créez un rôle et une relation de confiance permettant à Amazon Redshift d'assumer ce rôle. Suivez les instructions de la documentation IAM [pour créer un rôle pour un AWS service \(console\)](#)
 - Lorsqu'on vous demande de choisir un cas d'utilisation du AWS service, choisissez « Redshift - Personnalisable ».
 - Lorsque vous êtes invité à joindre une politique, choisissez celle que vous avez définie précédemment.

Note

Pour plus d'informations sur la configuration des rôles pour Amazon Redshift, consultez la section [Autoriser Amazon Redshift à accéder à d'autres AWS services en votre nom dans la](#) documentation Amazon Redshift.

5. Dans la console Amazon Redshift, associez le rôle à votre cluster Amazon Redshift. Suivez les instructions de la [documentation Amazon Redshift](#).

Sélectionnez l'option en surbrillance dans la console Amazon Redshift pour configurer ce paramètre :



Note

Par défaut, les tâches AWS Glue transmettent les informations d'identification temporaires Amazon Redshift créées à l'aide du rôle que vous avez spécifié pour exécuter la tâche. Nous vous déconseillons d'utiliser ces informations d'identification. Pour des raisons de sécurité, ces informations d'identification expirent au bout d'une heure.

Configuration du rôle pour la tâche AWS Glue

La tâche AWS Glue a besoin d'un rôle pour accéder au compartiment Amazon S3. Vous n'avez pas besoin d'autorisations IAM pour le cluster Amazon Redshift. Votre accès est contrôlé par la connectivité dans Amazon VPC et par les informations d'identification de votre base de données.

Configurer Amazon VPC

Pour configurer l'accès pour les magasins de données Amazon Redshift

1. Connectez-vous à la console Amazon Redshift AWS Management Console et ouvrez-la à l'adresse. <https://console.aws.amazon.com/redshiftv2/>
2. Dans le volet de navigation de gauche, choisissez Clusters.
3. Choisissez le nom du cluster auquel vous souhaitez accéder à partir d'AWS Glue.
4. Dans la section Cluster Properties (Propriétés du cluster), choisissez un groupe de sécurité dans VPC security groups (Groupes de sécurité VPC) afin de permettre à AWS Glue de l'utiliser. Enregistrez le nom du groupe de sécurité que vous avez choisi pour référence ultérieure. Le choix du groupe de sécurité ouvre la liste des groupes de sécurité de la EC2 console Amazon.
5. Choisissez le groupe de sécurité à modifier et accédez à l'onglet Inbound (Entrant).
6. Ajoutez une règle avec référence circulaire afin de permettre aux composants AWS Glue de communiquer. Plus spécifiquement, ajoutez ou confirmez qu'il existe une règle Type All TCP, que Protocol (Protocole) est TCP, que Port Range (Plage de ports) comprend tous les ports et que la valeur de Source est le même nom de groupe de sécurité que la valeur de Group ID (ID du groupe).

La règle entrante ressemble à ce qui suit :

Type	Protocole	Plage de ports	Source
Tous les TCP	TCP	0-65535	database-security-group

Par exemple :

Security Group: sg-19e1b768

Description

Inbound

Outbound

Tags

Edit

Type ⓘ	Protocol ⓘ	Port Range ⓘ	Source ⓘ
SSH	TCP	22	0.0.0.0/0
HTTPS	TCP	443	0.0.0.0/0

7. Ajoutez également une règle pour le trafic sortant. Ouvrez le trafic sortant pour tous les ports, par exemple :

Type	Protocole	Plage de ports	Destination
Tout le trafic	ALL	ALL	0.0.0.0/0

Ou créez une règle avec référence circulaire où Type est All TCP, Protocol (Protocole) est TCP, Port Range (Plage de ports) comprend tous les ports et dont la valeur de Destination est le même nom de groupe de sécurité que la valeur de Group ID (ID du groupe). Si vous utilisez un point de terminaison d'un VPC Amazon S3, ajoutez également une règle HTTPS pour l'accès à Amazon S3. Le *s3-prefix-list-id* est requis dans la règle du groupe de sécurité pour autoriser le trafic entre le VPC et le point de terminaison Amazon S3 VPC.

Par exemple :

Type	Protocole	Plage de ports	Destination
Tous les TCP	TCP	0-65535	<i>security-group</i>
HTTPS	TCP	443	<i>s3-prefix-list-id</i>

Configurer AWS Glue

Vous devez créer une connexion AWS Glue Data Catalog qui fournit les informations de connexion Amazon VPC.

Pour configurer la connectivité Amazon Redshift entre Amazon VPC et Glue dans la console AWS

1. Créez une connexion au catalogue de données en suivant les étapes décrites dans [the section called "Ajouter une AWS Glue connexion"](#). Après avoir créé la connexion, conservez le nom de la connexion pour l'étape suivante. *connectionName*
 - Lorsque vous sélectionnez un type de connexion, sélectionnez Amazon Redshift.
 - Lorsque vous sélectionnez un cluster Redshift, sélectionnez le nom de votre cluster.
 - Fournissez les informations de connexion par défaut pour un utilisateur Amazon Redshift sur votre cluster.
 - Vos paramètres Amazon VPC seront automatiquement configurés.

Note

Vous devrez fournir `PhysicalConnectionRequirements` manuellement pour votre Amazon VPC lorsque vous créez une connexion Amazon Redshift via le kit AWS SDK.

2. Dans la configuration de votre tâche AWS Glue *connectionName*, fournissez une connexion réseau supplémentaire.

Exemple : lecture à partir de tables Amazon Redshift

Vous pouvez lire à partir de clusters Amazon Redshift et des environnements Amazon Redshift sans serveur.

Conditions préalables : une table Amazon Redshift à partir de laquelle vous souhaitez lire. Suivez les étapes décrites dans la section précédente, [the section called "Configurer Redshift"](#) après quoi vous devriez avoir l'URI Amazon S3 pour un répertoire temporaire *temp-s3-dir* et un rôle IAM (dans le compte *role-account-id*). *rs-role-name*

Using the Data Catalog

Conditions préalables supplémentaires : une base de données et une table de catalogue de données pour la table Amazon Redshift à partir de laquelle vous souhaitez lire. Pour plus d'informations sur le catalogue de données, consultez [Découverte et catalogage des données](#). Après avoir créé une entrée pour votre table Amazon Redshift, vous identifierez votre connexion à l'aide d'un *redshift-dc-database-name* et *redshift-table-name*

Configuration : dans les options de votre fonction, vous identifierez votre table de catalogue de données avec les paramètres `database` et `table_name`. Vous identifierez votre répertoire temporaire Amazon S3 avec `redshift_tmp_dir`. Vous fournirez également *rs-role-name* en utilisant la `aws_iam_role` clé dans le `additional_options` paramètre.

```
glueContext.create_dynamic_frame.from_catalog(  
    database = "redshift-dc-database-name",  
    table_name = "redshift-table-name",  
    redshift_tmp_dir = args["temp-s3-dir"],  
    additional_options = {"aws_iam_role": "arn:aws:iam::role-account-id:role/rs-  
role-name"})
```

Connecting directly

Conditions préalables supplémentaires : vous aurez besoin du nom de votre table Amazon Redshift (. *redshift-table-name* Vous aurez besoin des informations de connexion JDBC pour le cluster Amazon Redshift qui stocke cette table. Vous fournirez vos informations de connexion avec *hostport*, *redshift-database-name*, *username* et *password*.

Vous pouvez récupérer vos informations de connexion depuis la console Amazon Redshift lorsque vous travaillez avec des clusters Amazon Redshift. Pour l'utilisation d'Amazon Redshift sans serveur, consultez [Connexion à Amazon Redshift sans serveur](#) dans la documentation Amazon Redshift.

Configuration : dans les options de votre fonction, vous identifierez vos paramètres de connexions avec `url`, `dbtable`, `user` et `password`. Vous identifierez votre répertoire temporaire Amazon S3 avec `redshift_tmp_dir`. Vous pouvez spécifier votre rôle IAM en utilisant `aws_iam_role` lorsque vous utilisez `from_options`. La syntaxe est similaire à celle de la connexion via le catalogue de données, mais vous placez les paramètres sur la carte `connection_options`.

C'est une mauvaise pratique de coder en dur les mots de passe dans les scripts AWS Glue. Envisagez de stocker vos mots de passe AWS Secrets Manager et de les récupérer dans votre script avec le SDK for Python (Boto3).

```
my_conn_options = {
    "url": "jdbc:redshift://host:port/redshift-database-name",
    "dbtable": "redshift-table-name",
    "user": "username",
    "password": "password",
    "redshiftTmpDir": args["temp-s3-dir"],
    "aws_iam_role": "arn:aws:iam::account id:role/rs-role-name"
}

df = glueContext.create_dynamic_frame.from_options("redshift", my_conn_options)
```

Exemple : écrire sur des tables Amazon Redshift

Vous pouvez sur des clusters Amazon Redshift et des environnements Amazon Redshift sans serveur.

Conditions préalables : un cluster Amazon Redshift et suivez les étapes de la [the section called “Configurer Redshift”](#) section précédente, après quoi vous devriez avoir l'URI Amazon S3 pour un répertoire temporaire et un rôle IAM *temp-s3-dir,rs-role-name*, (dans le compte). *role-account-id* Vous aurez également besoin d'un DynamicFrame dont vous souhaitez écrire le contenu dans la base de données.

Using the Data Catalog

Conditions préalables supplémentaires : une base de données de catalogue de données pour le cluster Amazon Redshift et la table sur laquelle vous souhaitez écrire. Pour plus d'informations sur le catalogue de données, consultez [Découverte et catalogage des données](#). Vous allez identifier votre connexion avec *redshift-dc-database-name* et la table cible avec *redshift-table-name*.

Configuration : dans les options de votre fonction, vous identifierez votre base de données de catalogue de données avec les paramètres `database`, puis vous fournirez votre table avec `table_name`. Vous identifierez votre répertoire temporaire Amazon S3 avec

`redshift_tmp_dir`. Vous fournirez également *rs-role-name* en utilisant la `aws_iam_role` clé dans le `additional_options` paramètre.

```
glueContext.write_dynamic_frame.from_catalog(  
    frame = input dynamic frame,  
    database = "redshift-dc-database-name",  
    table_name = "redshift-table-name",  
    redshift_tmp_dir = args["temp-s3-dir"],  
    additional_options = {"aws_iam_role": "arn:aws:iam::account-id:role/rs-role-name"}  
)
```

Connecting through a AWS Glue connection

Vous pouvez vous connecter directement à Amazon Redshift à l'aide de la méthode `write_dynamic_frame.from_options`. Toutefois, plutôt que d'insérer vos informations de connexion directement dans votre script, vous pouvez référencer les informations de connexion stockés dans une connexion au catalogue de données à l'aide de la méthode `from_jdbc_conf`. Vous pouvez le faire sans indexation de site web ou sans créer de tables de catalogue de données pour votre base de données. Pour plus d'informations sur les connexions au catalogue de données, consultez [Connexion aux données](#).

Conditions préalables supplémentaires : une base au catalogue de données pour votre base de données, une table Amazon Redshift à partir de laquelle vous souhaitez lire.

Configuration : vous allez identifier votre connexion au catalogue de données avec *dc-connection-name*. Vous identifierez votre base de données et votre table Amazon Redshift avec *redshift-table-name* et *redshift-database-name*. Vous fournirez les informations de connexion à votre catalogue de données avec `catalog_connection` et vos informations Amazon Redshift avec `dbtable` et `database`. La syntaxe est similaire à celle de la connexion via le catalogue de données, mais vous placez les paramètres sur la carte `connection_options`.

```
my_conn_options = {  
    "dbtable": "redshift-table-name",  
    "database": "redshift-database-name",  
    "aws_iam_role": "arn:aws:iam::role-account-id:role/rs-role-name"  
}
```



```
glueContext.write_dynamic_frame.from_jdbc_conf(  
    frame = input dynamic frame,  
    catalog_connection = "dc-connection-name",  
    connection_options = my_conn_options,  
    redshift_tmp_dir = args["temp-s3-dir"])
```

Référence des options de connexion Amazon Redshift

Les options de connexion de base utilisées pour toutes les connexions JDBC AWS Glue afin de configurer des informations telles que `url`, `user` et `password` sont cohérentes entre tous les types de JDBC. Pour plus d'informations sur les paramètres JDBC standards, consultez [the section called "Paramètres de connexion JDBC"](#).

Le type de connexion Amazon Redshift propose des options de connexion supplémentaires :

- "`redshiftTmpDir`" : (obligatoire) chemin Amazon S3 où les données temporaires peuvent être stockées lors de la copie à partir de la base de données.
- "`aws_iam_role`" : (facultatif) ARN pour un rôle IAM. La tâche AWS Glue transmettra ce rôle au cluster Amazon Redshift pour accorder au cluster les autorisations nécessaires pour exécuter les instructions de la tâche.

Options de connexion supplémentaires disponibles dans AWS Glue 4.0+

Vous pouvez également transmettre les options du nouveau connecteur Amazon Redshift via les options de connexion AWS Glue. Pour obtenir la liste complète des options de connecteur prises en charge, consultez la section relative aux paramètres SQL de Spark dans [Intégration Amazon Redshift pour Apache Spark](#).

Pour vous faciliter la tâche, nous vous rappelons ici certaines nouvelles options :

Nom	Obligatoire	Par défaut	Description
<code>autopushdown</code>	Non	TRUE	Applique le pushdown des prédicats et des requêtes en capturant et en

Nom	Obligatoire	Par défaut	Description
			analysant les plans logiques de Spark pour les opérations SQL. Les opérations sont traduites en une requête SQL, puis exécutées dans Amazon Redshift pour améliorer les performances.
autopushdown.s3_result_cache	Non	FALSE	Met en cache la requête SQL pour télécharger les données du mappage des chemins Amazon S3 en mémoire, afin que la même requête n'ait pas besoin de s'exécuter à nouveau dans la même session Spark. Pris en charge uniquement lorsqu'autopushdown est activé.

Nom	Obligatoire	Par défaut	Description
unload_s3_format	Non	PARQUET	PARQUET : décharge les résultats de la requête au format Parquet. TEXTE : décharge les résultats de la requête séparés par une barre verticale au format texte.
sse_kms_key	Non	N/A	La clé AWS SSE-KMS à utiliser pour le chiffrement pendant les UNLOAD opérations au lieu du chiffrement par défaut pour AWS.

Nom	Obligatoire	Par défaut	Description
extracopyoptions	Non	N/A	Une liste d'options supplémentaires à ajouter à la commande COPY d'Amazon Redshift lors du chargement de données, telles que TRUNCATECOLUMNS ou MAXERROR n (pour en savoir plus sur les autres options, voir COPY : paramètres facultatifs). Notez que ces options étant ajoutées à la fin de la commande COPY, seules des options qui ont du sens peuvent être utilisées à la fin de la commande. Cela devrait couvrir la plupart des cas d'utilisation possibles.
csvnullstring (expérimental)	Non	NULL	La valeur de chaîne à écrire pour les valeurs nulles lors de l'utilisation du tempformat CSV. Il doit s'agir d'une valeur qui n'apparaît pas dans vos données réelles.

Ces nouveaux paramètres peuvent être utilisés comme suit.

Nouvelles options destinées à améliorer les performances

Le nouveau connecteur intègre de nouvelles options d'amélioration des performances :

- `autopushdown` : activée par défaut.
- `autopushdown.s3_result_cache` : désactivée par défaut.
- `unload_s3_format` : PARQUET par défaut.

Pour plus d'informations sur l'utilisation de ces options, consultez [Intégration Amazon Redshift pour Apache Spark](#). Nous vous recommandons de ne pas activer `autopushdown.s3_result_cache` lorsque vous effectuez des opérations mixtes (lecture et écriture), car les résultats mis en cache peuvent contenir des informations périmées. L'option `unload_s3_format` est définie sur PARQUET par défaut pour la commande UNLOAD, afin d'améliorer les performances et de réduire les coûts de stockage. Pour utiliser le comportement par défaut de la commande UNLOAD, réinitialisez l'option sur TEXT.

Nouvelle option de chiffrement pour la lecture

Par défaut, les données du dossier temporaire que AWS Glue utilise lors de la lecture des données de la table Amazon Redshift sont chiffrées à l'aide du chiffrement SSE-S3. Pour utiliser les clés gérées par le client à partir de AWS Key Management Service (AWS KMS) pour chiffrer vos données, vous pouvez définir d'("sse_kms_key" # kmsKey) où KSMKey est l'[ID de clé AWS KMS, au lieu de](#) l'ancienne option ("extraunloadoptions" # s"ENCRYPTED KMS_KEY_ID '\$kmsKey') de configuration de la version 3.0. AWS Glue

```
datasource0 = glueContext.create_dynamic_frame.from_catalog(  
    database = "database-name",  
    table_name = "table-name",  
    redshift_tmp_dir = args["TempDir"],  
    additional_options = {"sse_kms_key": "<KMS_KEY_ID>"},  
    transformation_ctx = "datasource0"  
)
```

Prise en charge de l'URL JDBC basée sur IAM

Le nouveau connecteur prend en charge l'URL JDBC basée sur IAM, ce qui vous évite de transmettre un nom d'utilisateur/mot de passe ou un secret. Avec une URL JDBC basée sur IAM,

le connecteur utilise le rôle d'exécution des tâches pour accéder à la source de données Amazon Redshift.

Étape 1 : associez la politique minimale requise suivante à votre rôle d'exécution de tâches AWS Glue.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "VisualEditor0",
      "Effect": "Allow",
      "Action": "redshift:GetClusterCredentials",
      "Resource": [
        "arn:aws:redshift:<region>:<account>:dbgroup:<cluster name>/*",
        "arn:aws:redshift:*:<account>:dbuser:*/*",
        "arn:aws:redshift:<region>:<account>:dbname:<cluster name>/<database
name>"
      ]
    },
    {
      "Sid": "VisualEditor1",
      "Effect": "Allow",
      "Action": "redshift:DescribeClusters",
      "Resource": "*"
    }
  ]
}
```

Étape 2 : utilisez l'URL JDBC basée sur IAM comme suit. Spécifiez une nouvelle option DbUser avec le nom d'utilisateur Amazon Redshift qui permet de vous connecter.

```
conn_options = {
    // IAM-based JDBC URL
    "url": "jdbc:redshift:iam://<cluster name>:<region>/<database name>",
    "dbtable": dbtable,
    "redshiftTmpDir": redshiftTmpDir,
    "aws_iam_role": aws_iam_role,
    "DbUser": "<Redshift User name>" // required for IAM-based JDBC URL
}

redshift_write = glueContext.write_dynamic_frame.from_options(
    frame=dyf,
```

```
connection_type="redshift",
connection_options=conn_options
)

redshift_read = glueContext.create_dynamic_frame.from_options(
    connection_type="redshift",
    connection_options=conn_options
)
```

Note

DynamicFrame ne prend actuellement en charge qu'une URL JDBC basée sur IAM avec un DbUser dans le flux de travail GlueContext.create_dynamic_frame.from_options.

Migration de AWS Glue version 3.0 vers la version 4.0

Dans AWS Glue 4.0, les tâches ETL ont accès à un nouveau connecteur Amazon Redshift Spark et à un nouveau pilote JDBC avec différentes options et configurations. Le nouveau connecteur et le nouveau pilote Amazon Redshift ont été conçus dans un souci de performance et garantissent la cohérence transactionnelle de vos données. Ces produits sont décrits dans la documentation Amazon Redshift. Pour plus d'informations, consultez :

- [Intégration Amazon Redshift pour Apache Spark](#)
- [Pilote Amazon Redshift JDBC, version 2.1](#)

Restriction portant sur les noms et les identifiants des tables et des colonnes

Concernant le nom de la table Redshift, les exigences du nouveau connecteur et du nouveau pilote Amazon Redshift Spark sont plus restreintes. Pour plus d'informations, consultez la section [Noms et identifiants](#) qui explique comment définir le nom de votre table Amazon Redshift. Le flux de travail des signets de tâches peut ne pas fonctionner avec un nom de table non conforme aux règles et avec certains caractères (l'espace, par exemple).

Si vous utilisez d'anciennes tables dont les noms ne sont pas conformes aux règles relatives aux [noms et identifiants](#) et que vous rencontrez des problèmes liés aux signets (tâches dédiées au retraitement des données d'anciennes tables Amazon Redshift), nous vous recommandons de renommer vos tables. Pour plus d'informations, consultez les [exemples d'utilisation de la commande ALTER TABLE](#).

Modification de tempformat par défaut dans le Dataframe

Le connecteur Spark de AWS Glue version 3.0 définit par défaut le tempformat sur CSV lors de l'écriture dans Amazon Redshift. Par souci de cohérence, dans AWS Glue version 3.0, `DynamicFrame` définit toujours par défaut le tempformat de manière à utiliser le format CSV. Si vous avez déjà utilisé Spark Dataframe APIs directement avec le connecteur Amazon Redshift Spark, vous pouvez définir explicitement le format CSV dans tempformat `DataframeReader` les options/. `Writer` Sinon, tempformat est défini par défaut sur AVRO dans le nouveau connecteur Spark.

Changement de comportement : mapper le type de données Amazon Redshift REAL sur le type de données FLOAT de Spark au lieu de DOUBLE

Dans AWS Glue version 3.0, Amazon Redshift REAL est converti en type `DOUBLE` de Spark. Le nouveau connecteur Amazon Redshift Spark a mis à jour le comportement afin que le type Amazon Redshift `REAL` soit converti en type `FLOAT` de Spark et inversement. Si, conformément à un ancien cas d'utilisation, vous souhaitez toujours que le type `REAL` Amazon Redshift soit mappé sur un type Spark `DOUBLE`, vous pouvez utiliser la solution alternative suivante :

- Pour un `DynamicFrame`, mappez le type `Float` sur un type `Double` avec `DynamicFrame.ApplyMapping`. Pour un `Dataframe`, vous devez utiliser `cast`.

Exemple de code :

```
dyf_cast = dyf.apply_mapping([('a', 'long', 'a', 'long'), ('b', 'float', 'b',  
    'double')])
```

Gestion du type de données VARBYTE

Lorsque vous travaillez avec les types de données AWS Glue 3.0 et Amazon Redshift, AWS Glue 3.0 convertit Amazon VARBYTE Redshift en type Spark. `STRING` Cependant, le dernier connecteur Amazon Redshift Spark ne prend pas en charge ce type de VARBYTE données. Pour contourner cette limitation, vous pouvez [créer une vue Redshift](#) qui transforme les VARBYTE colonnes en un type de données compatible. Utilisez ensuite le nouveau connecteur pour charger les données à partir de cette vue au lieu de la table d'origine, ce qui garantit la compatibilité tout en maintenant l'accès à vos VARBYTE données.

Exemple de requête Redshift :

```
CREATE VIEW view_name AS SELECT FROM_VARBYTE(varbyte_column, 'hex') FROM table_name
```


Connexions Kafka

Vous pouvez utiliser une connexion Kafka pour lire et écrire dans des flux de données Kafka à l'aide des informations stockées dans une table du catalogue de données, ou en fournissant des informations pour accéder directement au flux de données. La connexion prend en charge un cluster Kafka ou un cluster Amazon Managed Streaming for Apache Kafka. Vous pouvez lire les informations de Kafka dans un Spark DataFrame, puis les convertir en AWS Glue DynamicFrame. Vous pouvez DynamicFrames écrire dans Kafka au format JSON. Si vous accédez directement au flux de données, utilisez ces options pour fournir des informations sur la façon d'accéder au flux de données.

Si vous utilisez `getCatalogSource` ou `create_data_frame_from_catalog` pour consommer des enregistrements provenant d'une source de streaming Kafka, `getCatalogSink` ou `write_dynamic_frame_from_catalog` pour écrire des enregistrements sur Kafka, et que la tâche contient les informations de base de données et de nom de table du catalogue de données, et que vous pouvez les utiliser pour obtenir certains paramètres de base pour la lecture à partir de la source de streaming Kafka. Si vous utilisez `getSource`, `getCatalogSink`, `getSourceWithFormat`, `createDataFrameFromOptions` ou `getSinkWithFormat`, ou `create_data_frame_from_options`, `write_dynamic_frame_from_catalog`, vous devez spécifier ces paramètres de base à l'aide des options de connexion décrites ici.

Vous pouvez spécifier les options de connexion pour Kafka à l'aide des arguments suivants pour les méthodes spécifiées dans la `GlueContext` classe.

- **Scala**
 - `connectionOptions` : utiliser avec `getSource`, `createDataFrameFromOptions`, `getSink`
 - `additionalOptions` : utiliser avec `getCatalogSource`, `getCatalogSink`
 - `options` : utiliser avec `getSourceWithFormat`, `getSinkWithFormat`
- **Python**
 - `connection_options` : utiliser avec `create_data_frame_from_options`, `write_dynamic_frame_from_options`
 - `additional_options` : utiliser avec `create_data_frame_from_catalog`, `write_dynamic_frame_from_catalog`
 - `options` : utiliser avec `getSource`, `getSink`

Pour les remarques et les restrictions concernant les tâches ETL de streaming, consultez [the section called “Restrictions et notes sur ETL en streaming”](#).

Configurer Kafka

Il n'y a aucune AWS condition préalable pour se connecter aux flux Kafka disponibles sur Internet.

Vous pouvez créer une connexion AWS Glue Kafka pour gérer vos identifiants de connexion. Pour de plus amples informations, veuillez consulter [the section called “Création d'une connexion pour un flux de données Kafka”](#). Dans la configuration de votre tâche AWS Glue, fournissez *connectionName* une connexion réseau supplémentaire, puis, dans votre appel de méthode, fournissez *connectionName* le *connectionName* paramètre.

Dans certains cas, vous devrez configurer des prérequis supplémentaires :

- Si vous utilisez Amazon Managed Streaming pour Apache Kafka avec l'authentification IAM, vous aurez besoin d'une configuration IAM appropriée.
- Si vous utilisez Amazon Managed Streaming pour Apache Kafka avec un Amazon VPC, vous aurez besoin d'une configuration Amazon VPC appropriée. Vous devez créer une connexion AWS Glue fournissant les informations de connexion Amazon VPC. Vous aurez besoin de la configuration de votre tâche pour inclure la connexion AWS Glue en tant que connexion réseau supplémentaire.

Pour plus d'informations sur les prérequis de la tâche ETL de streaming, consultez [the section called “Tâches ETL en streaming”](#).

Exemple : lecture à partir de flux Kafka

Utilisez conjointement avec [the section called “forEachBatch”](#).

Exemple pour la source de streaming Kafka :

```
kafka_options =  
  { "connectionName": "ConfluentKafka",  
    "topicName": "kafka-auth-topic",  
    "startingOffsets": "earliest",  
    "inferSchema": "true",  
    "classification": "json"  
  }
```

```
data_frame_datasource0 =  
    glueContext.create_data_frame.from_options(connection_type="kafka",  
        connection_options=kafka_options)
```

Exemple : écrire dans des flux Kafka

Exemples pour écrire à Kafka :

Exemple avec la `getSink` méthode :

```
data_frame_datasource0 =  
glueContext.getSink(  
    connectionType="kafka",  
    connectionOptions={  
        JsonOptions("""{  
            "connectionName": "ConfluentKafka",  
            "classification": "json",  
            "topic": "kafka-auth-topic",  
            "typeOfData": "kafka"}  
            """))},  
    transformationContext="dataframe_ApacheKafka_node1711729173428")  
.getDataFrame()
```

Exemple avec la `write_dynamic_frame.from_options` méthode :

```
kafka_options =  
    { "connectionName": "ConfluentKafka",  
      "topicName": "kafka-auth-topic",  
      "classification": "json"  
    }  
data_frame_datasource0 =  
    glueContext.write_dynamic_frame.from_options(connection_type="kafka",  
        connection_options=kafka_options)
```

Référence des options de connexion de Kafka

Lors de la lecture, utilisez les options de connexion suivantes avec `"connectionType"` :
`"kafka"` :

- `"bootstrap.servers"` (Obligatoire) Une liste de serveurs bootstrap URLs, par exemple, `combeb-1.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094`. Cette

option doit être spécifiée dans l'appel d'API ou définie dans les métadonnées de la table dans le catalogue de données.

- `"security.protocol"` (Obligatoire) Le protocole utilisé pour communiquer avec les agents. Les valeurs possibles sont `"SSL"` ou `"PLAINTEXT"`.
- `"topicName"` : (requis) liste de rubriques séparées par des virgules auxquelles s'abonner. Vous devez spécifier un seul et unique élément parmi `"topicName"`, `"assign"` ou `"subscribePattern"`.
- `"assign"` : (requis) chaîne JSON indiquant le `TopicPartitions` spécifique à utiliser. Vous devez spécifier un seul et unique élément parmi `"topicName"`, `"assign"` ou `"subscribePattern"`.

Exemple : `'{"topicA":[0,1],"topicB":[2,4]}'`

- `"subscribePattern"` : (obligatoire) chaîne d'expression rationnelle Java qui identifie la liste de rubriques à laquelle vous souhaitez vous abonner. Vous devez spécifier un seul et unique élément parmi `"topicName"`, `"assign"` ou `"subscribePattern"`.

Exemple : `'topic.*'`

- `"classification"` : (obligatoire) le format de fichier utilisé par les données de l'enregistrement. Obligatoire, sauf s'il est fourni par le catalogue de données.
- `"delimiter"` : (facultatif) le séparateur de valeurs utilisé lorsque `classification` est CSV. La valeur par défaut est « , ».
- `"startingOffsets"` : (facultatif) position de départ dans la rubrique Kafka à partir de laquelle lire les données. Les valeurs possibles sont `"earliest"` ou `"latest"`. La valeur par défaut est `"latest"`.
- `"startingTimestamp"` : (Facultatif, disponible uniquement pour AWS la version 4.0 ou ultérieure de Glue) Horodatage de l'enregistrement dans la rubrique Kafka à partir duquel les données doivent être lues. La valeur possible est une chaîne d'horodatage au format UTC dans le modèle `yyyy-mm-ddTHH:MM:SSZ` (où Z représente un décalage de fuseau horaire UTC avec un +/-). Par exemple : « `2023-04-04T08:00:00-04:00` »).

Remarque : seule l'une des propriétés « `StartingOffsets` » ou « `StartingTimestamp` » peut figurer dans la liste des options de connexion du script de streaming AWS Glue. L'inclusion de ces deux propriétés entraînera l'échec de la tâche.

- "endingOffsets" : (facultatif) point de fin lorsqu'une requête par lots est terminée. Les valeurs possibles sont "latest" ou une chaîne JSON qui spécifie un décalage de fin pour chaque TopicPartition.

Pour la chaîne JSON, le format est {"topicA":{"0":23,"1":-1},"topicB":{"0":-1}}. La valeur -1 en tant que décalage représente "latest".

- "pollTimeoutMs" : (facultatif) délai d'attente en millisecondes pour interroger les données de Kafka dans les exécuteurs de tâches Spark. La valeur par défaut est 600000.
- "numRetries" : (facultatif) nombre de nouvelles tentatives avant de ne pas récupérer les décalages Kafka. La valeur par défaut est 3.
- "retryIntervalMs" : (facultatif) temps d'attente en millisecondes avant d'essayer de récupérer les décalages Kafka. La valeur par défaut est 10.
- "maxOffsetsPerTrigger" : (facultatif) limite de taux sur le nombre maximal de décalages qui sont traités par intervalle de déclenchement. Le nombre total spécifié de décalages est réparti proportionnellement entre les topicPartitions des différents volumes. La valeur par défaut est null, ce qui signifie que le consommateur lit tous les décalages jusqu'au dernier décalage connu.
- "minPartitions" : (facultatif) nombre minimum de partitions à lire à partir de Kafka. La valeur par défaut est nulle, ce qui signifie que le nombre de partitions Spark est égal au nombre de partitions Kafka.
- "includeHeaders" : (facultatif) indique s'il faut inclure les en-têtes Kafka. Lorsque l'option est définie sur « true » (vrai), la sortie de données contiendra une colonne supplémentaire nommée « glue_streaming_kafka_headers » avec le type Array[Struct(key: String, value: String)]. La valeur définie par défaut est « false ». Cette option est disponible dans AWS Glue version 3.0 ou ultérieure.
- "schema" : (requis lorsque inferSchema est défini sur false) schéma à utiliser pour traiter la charge utile. Si la classification est avro, le schéma fourni doit être au format de schéma Avro. Si la classification n'est pas avro, le schéma fourni doit être au format de schéma DDL.

Voici quelques exemples de schémas.

Exemple in DDL schema format

```
'column1' INT, 'column2' STRING , 'column3' FLOAT
```

Exemple in Avro schema format

```
{
```

```
"type": "array",
"items":
{
  "type": "record",
  "name": "test",
  "fields":
  [
    {
      "name": "_id",
      "type": "string"
    },
    {
      "name": "index",
      "type":
      [
        "int",
        "string",
        "float"
      ]
    }
  ]
}
]
}
}
```

- **"inferSchema"** : (facultatif) la valeur par défaut est « false ». S'il est défini sur « true », le schéma sera détecté lors de l'exécution à partir de la charge utile dans `foreachbatch`.
- **"avroSchema"** : (obsolète) paramètre utilisé pour spécifier un schéma de données Avro lorsque le format Avro est utilisé. Ce paramètre est désormais obsolète. Utilisez le paramètre `schema`.
- **"addRecordTimestamp"** : (facultatif) lorsque cette option est définie sur « true », la sortie de données contient une colonne supplémentaire nommée « `__src_timestamp` » qui indique l'heure à laquelle l'enregistrement correspondant est reçu par la rubrique. La valeur par défaut est « false ». Cette option est prise en charge dans AWS Glue version 4.0 ou ultérieure.
- **"emitConsumerLagMetrics"** : (Facultatif) Lorsque l'option est définie sur « vrai », pour chaque lot, elle émet les métriques correspondant à la durée comprise entre le plus ancien enregistrement reçu par le sujet et le moment où il arrive AWS Glue à CloudWatch. Le nom de la métrique est « `glue.driver.streaming` ». `maxConsumerLagInMs` ». La valeur par défaut est « false ». Cette option est prise en charge dans AWS Glue version 4.0 ou ultérieure.

Lorsque vous écrivez, utilisez les options de connexion suivantes avec **"connectionType"** :
"kafka" :

- `"connectionName"`(Obligatoire) Nom de la connexion AWS Glue utilisée pour se connecter au cluster Kafka (similaire à la source Kafka).
- `"topic"`(Obligatoire) Si une colonne de sujet existe, sa valeur est utilisée comme sujet lors de l'écriture de la ligne donnée dans Kafka, sauf si l'option de configuration du sujet est définie. C'est-à-dire que l'option `topic` de configuration remplace la colonne du sujet.
- `"partition"`(Facultatif) Si un numéro de partition valide est spécifié, il `partition` sera utilisé lors de l'envoi de l'enregistrement.

Si aucune partition n'est spécifiée mais que a key est présent, une partition sera choisie à l'aide d'un hachage de la clé.

Si ni l'un key ni l'autre n'`partition`est présent, une partition sera choisie en partitionnant de manière permanente ces modifications lorsqu'au moins des octets `batch.size` seront produits sur la partition.

- `"key"`(Facultatif) Utilisé pour le partitionnement s'il `partition` est nul.
- `"classification"`(Facultatif) Format de fichier utilisé par les données de l'enregistrement. Nous prenons uniquement en charge les formats JSON, CSV et Avro.

Avec le format Avro, nous pouvons fournir un AvroSchema personnalisé avec lequel sérialiser, mais notez que cela doit également être fourni sur la source pour la désérialisation. Sinon, par défaut, il utilise Apache AvroSchema pour la sérialisation.

En outre, vous pouvez ajuster le récepteur Kafka selon les besoins en mettant à jour les paramètres de configuration du [producteur Kafka](#). Notez qu'il n'existe aucune liste d'autorisation pour les options de connexion, toutes les paires clé-valeur sont conservées telles quelles sur le récepteur.

Cependant, il existe une petite liste d'options refusées qui ne prendront pas effet. Pour plus d'informations, consultez la section [Configurations spécifiques à Kafka](#).

Connexions Azure Cosmos DB

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire dans des conteneurs existants dans Azure Cosmos DB à l'aide de l'API NoSQL de AWS Glue 4.0 et des versions ultérieures. Vous pouvez définir ce qu'il faut lire dans Azure Cosmos DB à l'aide d'une requête SQL. Vous vous connectez à Azure Cosmos DB à l'aide d'une clé Azure Cosmos DB stockée AWS Secrets Manager via une connexion AWS Glue.

Pour plus d'informations sur Azure Cosmos DB pour NoSQL, consultez [la documentation Azure](#).

Configuration des connexions Azure Cosmos DB

Pour vous connecter à Azure Cosmos DB depuis AWS Glue, vous devez créer et stocker votre clé de base de données Azure Cosmos dans un AWS Secrets Manager secret, puis associer ce secret à une connexion Azure Cosmos DB AWS Glue.

Prérequis :

- Dans Azure, vous devrez identifier ou générer une clé de base de données Azure Cosmos à utiliser par AWS Glue, `cosmosKey`. Pour plus d'informations, consultez la section [Accès sécurisé aux données dans Azure Cosmos DB](#) dans la documentation Azure.

Pour configurer une connexion à Azure Cosmos DB :

1. Dans AWS Secrets Manager, créez un secret à l'aide de votre clé de base de données Azure Cosmos. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret `secretName` pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé `spark.cosmos.accountKey` contenant la valeur. `cosmosKey`
2. Dans la console AWS Glue, créez une connexion en suivant les étapes décrites dans [the section called "Ajouter une AWS Glue connexion"](#). Après avoir créé la connexion, conservez le nom de la connexion pour une utilisation future dans AWS Glue. `connectionName`
 - Lorsque vous sélectionnez un type de connexion, sélectionnez Azure Cosmos DB.
 - Lorsque vous sélectionnez un AWS secret, fournissez `secretName`.

Après avoir créé une connexion AWS Glue Azure Cosmos DB, vous devez effectuer les étapes suivantes avant d'exécuter votre tâche AWS Glue :

- Accordez au rôle IAM associé à votre tâche AWS Glue l'autorisation de lire `secretName`.
- Dans la configuration de votre tâche AWS Glue `connectionName`, fournissez une connexion réseau supplémentaire.

Lire à partir de la Azure Cosmos DB pour les conteneurs NoSQL

Prérequis :

- Un conteneur Azure Cosmos DB pour NoSQL à partir duquel vous souhaitez lire. Vous aurez besoin des informations d'identification du conteneur.

Un conteneur Azure Cosmos pour NoSQL est identifié par sa base de données et son conteneur. Vous devez fournir les noms de base de données et de conteneur lorsque vous vous connectez à l'API Azure Cosmos pour NoSQL. *cosmosDBName cosmosContainerName*

- Une connexion AWS Glue Azure Cosmos DB configurée pour fournir des informations d'authentification et de localisation réseau. Pour cela, suivez les étapes de la procédure précédente, Pour configurer une connexion à Azure Cosmos DB. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.

Par exemple :

```
azurecosmos_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="azurecosmos",  
    connection_options={  
        "connectionName": connectionName,  
        "spark.cosmos.database": cosmosDBName,  
        "spark.cosmos.container": cosmosContainerName,  
    }  
)
```

Vous pouvez également fournir une requête SQL SELECT pour filtrer les résultats renvoyés à votre DynamicFrame. Vous devrez configurer query.

Par exemple :

```
azurecosmos_read_query = glueContext.create_dynamic_frame.from_options(  
    connection_type="azurecosmos",  
    connection_options={  
        "connectionName": "connectionName",  
        "spark.cosmos.database": cosmosDBName,  
        "spark.cosmos.container": cosmosContainerName,  
        "spark.cosmos.read.customQuery": "query"  
    }  
)
```

Écrire dans Azure Cosmos DB pour les conteneurs NoSQL

Cet exemple écrit des informations à partir d'une base de données existante `DynamicFrame` *dynamicFrame* dans Azure Cosmos DB. Si le conteneur contient déjà des informations, AWS Glue ajoutera les données de votre `DynamicFrame`. Si les informations contenues dans le conteneur ont un schéma différent de celui des informations que vous écrivez, vous rencontrerez des erreurs.

Prérequis :

- Une table Azure Cosmos DB dans laquelle vous souhaitez écrire. Vous aurez besoin des informations d'identification du conteneur. Vous devez créer le conteneur avant d'appeler la méthode de connexion.

Un conteneur Azure Cosmos pour NoSQL est identifié par sa base de données et son conteneur. Vous devez fournir les noms de base de données et de conteneur lorsque vous vous connectez à l'API Azure Cosmos pour NoSQL. *cosmosDBName cosmosContainerName*

- Une connexion AWS Glue Azure Cosmos DB configurée pour fournir des informations d'authentification et de localisation réseau. Pour cela, suivez les étapes de la procédure précédente, Pour configurer une connexion à Azure Cosmos DB. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.

Par exemple :

```
azurecosmos_write = glueContext.write_dynamic_frame.from_options(  
    frame=dynamicFrame,  
    connection_type="azurecosmos",  
    connection_options={  
        "connectionName": connectionName,  
        "spark.cosmos.database": cosmosDBName,  
        "spark.cosmos.container": cosmosContainerName  
    }  
)
```

Référence des options de connexion Azure Cosmos DB

- `connectionName` — Obligatoire. Utilisé pour la lecture/l'écriture. Nom d'une connexion AWS Glue Azure Cosmos DB configurée pour fournir des informations d'authentification et de localisation réseau à votre méthode de connexion.
- `spark.cosmos.database` — Obligatoire. Utilisé pour la lecture/l'écriture. Valeurs valides : noms des bases de données. Nom de la base de données Azure Cosmos DB pour NoSQL.

- `spark.cosmos.container` — Obligatoire. Utilisé pour la lecture/l'écriture. Valeurs valides : noms des conteneurs. Nom du conteneur Azure Cosmos DB pour NoSQL.
- `spark.cosmos.read.customQuery` : utilisé pour la lecture. Valeurs valides : requêtes SELECT SQL. Requête personnalisée pour sélectionner les documents à lire.

Connexions Azure SQL

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire dans des tables sur des instances gérées Azure SQL dans AWS Glue 4.0 et versions ultérieures. Vous pouvez définir ce qu'il faut lire dans Azure SQL à l'aide d'une requête SQL. Vous vous connectez à Azure SQL à l'aide des informations d'identification d'utilisateur et de mot de passe stockées AWS Secrets Manager via une connexion AWS Glue.

Pour plus d'informations sur Azure SQL, consultez [la documentation Azure SQL](#).

Configuration des connexions Azure SQL

Pour vous connecter à Azure SQL depuis AWS Glue, vous devez créer et stocker vos informations d'identification Azure SQL dans un AWS Secrets Manager secret, puis associer ce secret à une connexion Azure SQL AWS Glue.

Pour configurer une connexion à Azure SQL :

1. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification Azure SQL. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé `user` contenant la valeur. *azuresqlUsername*
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé `password` contenant la valeur. *azuresqlPassword*
2. Dans la console AWS Glue, créez une connexion en suivant les étapes décrites dans [the section called "Ajouter une AWS Glue connexion"](#). Après avoir créé la connexion, conservez le nom de la connexion pour une utilisation future dans AWS Glue. *connectionName*
 - Lorsque vous sélectionnez un type de connexion, sélectionnez Azure SQL.

- Lorsque vous fournissez une URL Azure SQL, fournissez une URL de point de terminaison JDBC.

La URL doit avoir le format suivant :

`jdbc:sqlserver://databaseServerName:databasePort;databaseName=azuresqlDBName`

AWS Glue nécessite les propriétés d'URL suivantes :

- `databaseName` – une base de données par défaut dans Azure SQL à laquelle se connecter.

Pour plus d'informations sur JDBC URLs pour Azure SQL Managed Instances, consultez la documentation [Microsoft](#).

- Lorsque vous sélectionnez un AWS secret, indiquez-le `secretName`.

Après avoir créé une connexion AWS Glue Azure SQL, vous devez effectuer les étapes suivantes avant d'exécuter votre tâche AWS Glue :

- Accordez au rôle IAM associé à votre tâche AWS Glue l'autorisation de lire `secretName`.
- Dans la configuration de votre tâche AWS Glue `connectionName`, fournissez une connexion réseau supplémentaire.

Lire à partir de tables SQL Azure

Prérequis :

- Une table Azure SQL à partir de laquelle vous souhaitez lire. Vous aurez besoin d'informations d'identification pour la table, `databaseName` et `tableIdentifier`.

Une table Azure SQL est identifiée par sa base de données, son schéma et son nom de table. Vous devez fournir le nom de la base de données et le nom de la table lorsque vous vous connectez à Azure SQL. Vous devez également fournir le schéma s'il n'est pas « public » par défaut. La base de données est fournie via une propriété d'URL dans `connectionName`, un schéma et un nom de table via `ledbtable`.

- Une connexion SQL AWS Glue Azure configurée pour fournir des informations d'authentification. Suivez les étapes de la procédure précédente Pour configurer une connexion à Azure SQL afin de configurer vos informations d'authentification. Vous aurez besoin du nom de la connexion AWS Glue, `connectionName`.

Par exemple :

```
azuresql_read_table = glueContext.create_dynamic_frame.from_options(  
    connection_type="azuresql",  
    connection_options={  
        "connectionName": "connectionName",  
        "dbtable": "tableIdentifier"  
    }  
)
```

Vous pouvez également fournir une requête SQL SELECT pour filtrer les résultats renvoyés à votre DynamicFrame. Vous devrez configurer query.

Par exemple :

```
azuresql_read_query = glueContext.create_dynamic_frame.from_options(  
    connection_type="azuresql",  
    connection_options={  
        "connectionName": "connectionName",  
        "query": "query"  
    }  
)
```

Écrire dans des tables Azure SQL

Cet exemple écrit des informations à partir d'un DynamicFrame fichier existant *dynamicFrame* dans Azure SQL. Si le tableau contient déjà des informations, AWS Glue ajoutera les données de votre DynamicFrame.

Prérequis :

- Une table Azure SQL dans laquelle vous souhaitez écrire. Vous aurez besoin d'informations d'identification pour la table, *databaseName* et *tableIdentifier*.

Une table Azure SQL est identifiée par sa base de données, son schéma et son nom de table. Vous devez fournir le nom de la base de données et le nom de la table lorsque vous vous connectez à Azure SQL. Vous devez également fournir le schéma s'il n'est pas « public » par défaut. La base de données est fournie via une propriété d'URL dans *connectionName*, un schéma et un nom de table via *dbtable*.

- Informations d'authentification Azure SQL. Suivez les étapes de la procédure précédente Pour configurer une connexion à Azure SQL afin de configurer vos informations d'authentification. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.

Par exemple :

```
azuresql_write = glueContext.write_dynamic_frame.from_options(  
    connection_type="azuresql",  
    connection_options={  
        "connectionName": "connectionName",  
        "dbtable": "tableIdentifier"  
    }  
)
```

Référence des options de connexion Azure SQL

- *connectionName* — Obligatoire. Utilisé pour la lecture/l'écriture. Le nom d'une connexion SQL AWS Glue Azure configurée pour fournir des informations d'authentification à votre méthode de connexion.
- *databaseName* : utilisé pour la lecture/l'écriture. Valeurs valides : noms des bases de données Azure SQL. Le nom de la base de données dans Azure SQL à laquelle se connecter.
- *dbtable* — obligatoire pour l'écriture, obligatoire pour la lecture à moins qu'une query ne soit fournie. Utilisé pour les combinaisons de Read/Write. Valid Values: Names of Azure SQL tables, or period separated schema/table noms. Utilisées pour spécifier la table et le schéma qui identifient la table à laquelle se connecter. Le schéma par défaut est « public ». Si votre table n'est pas dans un schéma par défaut, fournissez ces informations dans le formulaire *schemaName.tableName*.
- *query* : utilisé pour la lecture. Une requête Transact-SQL SELECT définissant ce qui doit être récupéré lors de la lecture à partir d'Azure SQL. Pour plus d'informations, consultez la [documentation Microsoft](#).

BigQuery connexions

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire dans des tableaux de Google BigQuery dans AWS Glue 4.0 et versions ultérieures. Vous pouvez le lire à l' aide d'une requête Google SQL. Vous vous connectez à BigQuery l'aide des informations d'identification stockées AWS Secrets Manager via une connexion AWS Glue.

Pour plus d'informations sur Google BigQuery, consultez le [BigQuery site Web de Google Cloud](#).

Configuration des BigQuery connexions

Pour vous connecter à Google BigQuery depuis AWS Glue, vous devez créer et stocker vos informations d'identification Google Cloud Platform dans un AWS Secrets Manager secret, puis associer ce secret à une connexion Google BigQuery AWS Glue.

Pour configurer une connexion à BigQuery :

1. Dans Google Cloud Platform, créez et identifiez les ressources pertinentes :
 - Créez ou identifiez un projet GCP contenant des BigQuery tables auxquelles vous souhaitez vous connecter.
 - Activez l' API BigQuery. Pour plus d'informations, voir [Utiliser l'API BigQuery Storage Read pour lire les données des tables](#).
2. Dans Google Cloud Platform, créez et exportez les informations d'identification du compte de service :

Vous pouvez utiliser l'assistant BigQuery d'identification pour accélérer cette étape : [créer des informations d'identification](#).

Pour créer un compte de service dans GCP, suivez le didacticiel disponible dans la section [Créer des comptes de service](#).

- Lorsque vous sélectionnez un projet, sélectionnez le projet contenant votre BigQuery tableau.
- Lorsque vous sélectionnez des rôles GCP IAM pour votre compte de service, ajoutez ou créez un rôle qui accordera les autorisations appropriées pour exécuter des BigQuery tâches de lecture, d'écriture ou de création BigQuery de tables.

Pour créer des informations d'identification pour votre compte de service, suivez le didacticiel disponible dans la section [Créer une clé de compte de service](#).

- Lorsque vous sélectionnez le type de clé, sélectionnez JSON.

Vous devriez maintenant avoir téléchargé un fichier JSON contenant les informations d'identification de votre compte de service. Il doit ressembler à l'exemple ci-dessous.

```
{  
  "type": "service_account",
```

```

"project_id": "*****",
"private_key_id": "*****",
"private_key": "*****",
"client_email": "*****",
"client_id": "*****",
"auth_uri": "https://accounts.google.com/o/oauth2/auth",
"token_uri": "https://oauth2.googleapis.com/token",
"auth_provider_x509_cert_url": "https://www.googleapis.com/oauth2/v1/certs",
"client_x509_cert_url": "*****",
"universe_domain": "googleapis.com"
}

```

3. Encodage en base64 le fichier d'informations d'identification que vous avez téléchargé. AWS CloudShell Lors d'une session ou similaire, vous pouvez le faire depuis la ligne de commande en exécutant `cat credentialsFile.json | base64 -w 0`. Conservez le résultat de cette commande, *credentialString*.
4. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification Google Cloud Platform. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé `credentials` contenant la valeur. *credentialString*
5. Dans le catalogue de données AWS Glue, créez une connexion en suivant les étapes décrites dans [the section called "Ajouter une AWS Glue connexion"](#). Après avoir créé la connexion, conservez le nom de la connexion pour l'étape suivante. *connectionName*
 - Lorsque vous sélectionnez un type de connexion, sélectionnez Google BigQuery.
 - Lorsque vous sélectionnez un AWS secret, fournissez *secretName*.
6. Accordez au rôle IAM associé à votre tâche AWS Glue l'autorisation de lire *secretName*.
7. Dans la configuration de votre tâche AWS Glue *connectionName*, fournissez une connexion réseau supplémentaire.

Lecture à partir de BigQuery tables

Prérequis :

- Un BigQuery tableau que vous aimeriez lire. Vous aurez besoin des noms de BigQuery table et de jeu de données dans le formulaire `[dataset].[table]`. Appelons ça *tableName*.

- Le projet de facturation de la BigQuery table. Vous aurez besoin du nom du projet, *parentProject*. S'il n'existe aucun projet parent de facturation, utilisez le projet contenant la table.
- BigQuery informations d'authentification. Suivez les étapes pour gérer vos informations de connexion avec AWS Glue afin de configurer vos informations d'authentification. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.

Par exemple :

```
bigquery_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="bigquery",  
    connection_options={  
        "connectionName": "connectionName",  
        "parentProject": "parentProject",  
        "sourceType": "table",  
        "table": "tableName",  
    }  
)
```

Vous pouvez également fournir une requête pour filtrer les résultats renvoyés à votre DynamicFrame. Vous devrez configurer query, sourceType, viewsEnabled et materializationDataset.

Par exemple :

Prérequis supplémentaires :

Vous devrez créer ou identifier un BigQuery jeu de données dans lequel vous BigQuery pourrez écrire des vues matérialisées pour vos requêtes. *materializationDataset*

Vous devrez accorder les autorisations GCP IAM appropriées à votre compte de service pour créer des tables dans. *materializationDataset*

```
glueContext.create_dynamic_frame.from_options(  
    connection_type="bigquery",  
    connection_options={  
        "connectionName": "connectionName",  
        "materializationDataset": materializationDataset,  
        "parentProject": "parentProject",  
        "viewsEnabled": "true",  
        "sourceType": "query",  
        "query": "select * from bqtest.test"
```

```
}  
)
```

Écrire sur des BigQuery tables

Cet exemple écrit directement dans le BigQuery service. BigQuery supporte également la méthode d'écriture « indirecte ». Pour plus d'informations sur les écritures indirectes, consultez [the section called "Utiliser l'écriture indirecte avec Google BigQuery"](#).

Prérequis :

- Une BigQuery table dans laquelle vous souhaitez écrire. Vous aurez besoin des noms de BigQuery table et de jeu de données dans le formulaire `[dataset].[table]`. Vous pouvez également fournir un nouveau nom de table qui sera automatiquement créé. Appelons ça *tableName*.
- Le projet de facturation de la BigQuery table. Vous aurez besoin du nom du projet, *parentProject*. S'il n'existe aucun projet parent de facturation, utilisez le projet contenant la table.
- BigQuery informations d'authentification. Suivez les étapes pour gérer vos informations de connexion avec AWS Glue afin de configurer vos informations d'authentification. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.

Par exemple :

```
bigquery_write = glueContext.write_dynamic_frame.from_options(  
    frame=frameToWrite,  
    connection_type="bigquery",  
    connection_options={  
        "connectionName": "connectionName",  
        "parentProject": "parentProject",  
        "writeMethod": "direct",  
        "table": "tableName",  
    }  
)
```

BigQuery référence des options de connexion

- `project` : par défaut, le compte de service Google Cloud par défaut. Utilisé pour la lecture/l'écriture. Le nom d'un projet Google Cloud associé à votre table.

- `table` : (obligatoire) utilisé pour la lecture/l'écriture. Le nom de votre BigQuery table au format `[[project:]dataset.]`.
- `dataset` : obligatoire lorsqu'il n'est pas défini par l'option `table`. Utilisé pour la lecture/l'écriture. Le nom du jeu de données contenant votre BigQuery table.
- `parentProject` : par défaut, le compte de service Google Cloud par défaut. Utilisé pour la lecture/l'écriture. Nom d'un projet Google Cloud associé à `project` utilisé pour la facturation.
- `sourceType` : utilisé pour la lecture. Obligatoire lors de la lecture. Valeurs valides : `table query` indique à AWS Glue si vous allez lire par table ou par requête.
- `materializationDataset` : utilisé pour la lecture. Valeurs valides : chaînes. Nom d'un BigQuery ensemble de données utilisé pour stocker les matérialisations des vues.
- `viewsEnabled` : utilisé pour la lecture. Par défaut : `false`. Valeurs valides : `true`, `false`. Détermine si BigQuery vous souhaitez utiliser les vues.
- `query` : utilisé pour la lecture. Utilisé quand `viewsEnabled` est `true`. Une requête GoogleSQL DQL.
- `temporaryGcsBucket` : utilisé pour écrire. Obligatoire lorsque `writeMethod` est défini sur la valeur par défaut (`indirect`). Nom d'un bucket Google Cloud Storage utilisé pour stocker une forme intermédiaire de vos données lorsque vous y écrivez BigQuery.
- `writeMethod` : `indirect` par défaut. Valeurs valides : `direct`, `indirect`. Utilisé pour écrire. Spécifie la méthode utilisée pour écrire les données.
 - S'il est défini sur `direct`, votre connecteur écrira à l'aide de l'API BigQuery Storage Write.
 - S'il est défini sur `indirect`, votre connecteur écrira dans Google Cloud Storage, puis le transférera à l' aide de l' API BigQuery aide d'une opération de chargement. Votre compte de service Google Cloud aura besoin des autorisations GCS appropriées.

Utiliser l'écriture indirecte avec Google BigQuery

Cet exemple utilise l'écriture indirecte, qui écrit des données dans Google Cloud Storage et les copie dans Google BigQuery.

Prérequis :

Vous aurez besoin d'un bucket Google Cloud Storage temporaire *temporaryBucket*.

Le rôle GCP IAM pour le compte de service GCP de AWS Glue nécessitera les autorisations GCS appropriées pour y accéder. *temporaryBucket*

Configuration supplémentaire :

Pour configurer l'écriture indirecte avec BigQuery :

1. Évaluez [the section called "Configuration BigQuery"](#) et localisez ou retéléchargez le fichier JSON de vos informations d'identification GCP. Identifiez `secretName`, le AWS Secrets Manager secret de la connexion Google BigQuery AWS Glue utilisée dans le cadre de votre travail.
2. Téléchargez le fichier JSON de vos informations d'identification sur un emplacement Amazon S3 correctement sécurisé. Conservez le chemin d'accès au fichier `s3secretpath` pour les étapes futures.
3. Modifier `secretName`, ajouter la `spark.hadoop.google.cloud.auth.service.account.json.keyfile` clé. Définissez la valeur sur `s3secretpath`.
4. Accordez à votre job AWS Glue Amazon S3 IAM des autorisations d'accès `s3secretpath`.

Vous pouvez désormais fournir l'emplacement temporaire de votre compartiment GCS à votre méthode d'écriture. Vous n'avez pas besoin de fournir `writeMethod`, car `indirect` est historiquement la valeur par défaut.

```
bigquery_write = glueContext.write_dynamic_frame.from_options(  
    frame=frameToWrite,  
    connection_type="bigquery",  
    connection_options={  
        "connectionName": "connectionName",  
        "parentProject": "parentProject",  
        "temporaryGcsBucket": "temporaryBucket",  
        "table": "tableName",  
    }  
)
```

Connexions JDBC

Certains types de bases de données, généralement relationnelles, prennent en charge la connexion via le standard JDBC. Pour plus d'informations sur JDBC, consultez la documentation de l'API [Java JDBC](#). AWS Glue prend en charge nativement la connexion à certaines bases de données via ses connecteurs JDBC. Les bibliothèques JDBC sont fournies dans les jobs Glue Spark. AWS Lorsque vous vous connectez à ces types de bases de données à l'aide des bibliothèques AWS Glue, vous avez accès à un ensemble standard d'options.

Les valeurs `connectionType` JDBC sont les suivantes :

- `"connectionType": "sqlserver"` : Désigne une connexion à une base de données Microsoft SQL Server.
- `"connectionType": "mysql"` : Désigne une connexion à une base de données MySQL.
- `"connectionType": "oracle"` : Désigne une connexion à une base de données Oracle.
- `"connectionType": "postgresql"` : Désigne une connexion à une base de données PostgreSQL.
- `"connectionType": "redshift"` : désigne une connexion à une base de données Amazon Redshift. Pour de plus amples informations, veuillez consulter [the section called “Connexions Redshift”](#).

Le tableau suivant répertorie les versions du pilote JDBC prises en charge par AWS Glue.

Produit (langue française non garantie)	Versions du pilote JDBC pour Glue 5.0	Versions de pilotes JDBC pour Glue 4.0	Versions de pilotes JDBC pour Glue 3.0	Versions de pilotes JDBC pour Glue 0.9, 1.0, 2.0
Microsoft SQL Server	10.2.0	9.4.0	7.x	6.x
MySQL	8,0,33	8.0.23	8.0.23	5.1
Oracle Database	23,3.0,23,09	21,7	21,1	11.2
PostgreSQL	42.7.3	42,3.6	42,2,18	42.1.x
Amazon Redshift *	redshift-jdbc42-2.1.0.29	redshift-jdbc42-2.1.0.16	redshift-jdbc41-1.2.12.1017	redshift-jdbc41-1.2.12.1017

* Pour le type de connexion Amazon Redshift, toutes les autres paires nom/valeur des options incluses dans les options de connexion pour une connexion JDBC, y compris les options de formatage, sont transmises directement au SparkSQL sous-jacent. DataSource Dans les jobs AWS Glue with Spark de AWS Glue 4.0 et des versions ultérieures, le connecteur natif AWS Glue pour

Amazon Redshift utilise l'intégration Amazon Redshift pour Apache Spark. Pour plus d'informations, consultez [Intégration d'Amazon Redshift à Apache Spark](#). Pour les versions précédentes, consultez [Amazon Redshift data source for Spark](#).

Pour configurer votre Amazon VPC afin de vous connecter aux magasins de données Amazon RDS à l'aide de JDBC, reportez-vous à [the section called “Configuration d'Amazon VPC pour se connecter aux magasins de données Amazon RDS”](#).

 Note

AWS Les tâches Glue ne sont associées qu'à un seul sous-réseau lors d'une exécution. Cela peut avoir une incidence sur votre capacité à vous connecter à plusieurs sources de données par le biais de la même tâche. Ce comportement n'est pas limité aux sources JDBC.

Rubriques

- [Référence des options de connexion JDBC](#)
- [Utiliser sampleQuery](#)
- [Utiliser un pilote JDBC personnalisé](#)
- [Lecture en parallèle à partir de tables JDBC](#)
- [Configuration d'Amazon VPC pour les connexions JDBC aux magasins de données Amazon RDS à partir de AWS Glue](#)

Référence des options de connexion JDBC

Si une connexion JDBC AWS Glue est déjà définie, vous pouvez réutiliser les propriétés de configuration qui y sont définies, telles que : url, utilisateur et mot de passe ; vous n'avez donc pas à les spécifier dans le code en tant qu'options de connexion. Cette fonctionnalité est disponible dans AWS Glue 3.0 et versions ultérieures. Pour ce faire, utilisez les propriétés de connexion suivantes :

- "useConnectionProperties" : à définir sur « true » pour indiquer que vous souhaitez utiliser la configuration à partir d'une connexion.
- "connectionName" : saisissez le nom de connexion à partir duquel récupérer la configuration. La connexion doit être définie dans la même région que la tâche.

Utilisez ces options de connexion avec les connexions JDBC :

- "url" : (Obligatoire) URL JDBC de la base de données.
- "dbtable" : (obligatoire) table de la base de données à partir de laquelle la lecture doit s'effectuer. Pour les magasins de données JDBC qui prennent en charge les schémas dans une base de données, spécifiez `schema.table-name`. Si aucun schéma n'est fourni, c'est le schéma « public » par défaut qui est utilisé.
- "user" : (Obligatoire) Nom d'utilisateur à utiliser lors de la connexion.
- "password" : (Obligatoire) Mot de passe à utiliser lors de la connexion.
- (Facultatif) les options suivantes vous permettent de fournir un pilote JDBC personnalisé. Utilisez ces options si vous devez utiliser un pilote que AWS Glue ne prend pas en charge de manière native.

Les tâches ETL peuvent utiliser différentes versions de pilote JDBC pour la source de données et la cible, même si la source et la cible sont le même produit de base de données. Cela vous permet de migrer des données entre les bases de données source et cible avec différentes versions. Pour utiliser ces options, vous devez d'abord charger le fichier JAR du pilote JDBC vers Amazon S3.

- "customJdbcDriverS3Path" : chemin Amazon S3 du pilote JDBC personnalisé.
- "customJdbcDriverClassName" : nom de la classe du pilote JDBC.
- "bulkSize" : (Facultatif) Utilisé pour configurer des insertions parallèles pour accélérer les charges groupées dans les cibles JDBC. Spécifiez une valeur entière pour le degré de parallélisme à utiliser lors de l'écriture ou de l'insertion de données. Cette option permet d'améliorer les performances d'écriture dans les bases de données telles que le référentiel d'utilisateurs Arch (AUR).
- "hashfield" : (facultatif) chaîne utilisée pour indiquer le nom d'une colonne de la table JDBC à utiliser pour diviser les données en partitions lors de la lecture de tables JDBC en parallèle. Indiquez « hashfield » OU « hashexpression ». Pour de plus amples informations, veuillez consulter [the section called "Lecture en parallèle à partir de JDBC"](#).
- "hashexpression" : (facultatif) une clause de sélection SQL renvoyant un nombre entier. Utilisée pour diviser les données d'une table JDBC en partitions lors de la lecture de tables JDBC en parallèle. Indiquez « hashfield » OU « hashexpression ». Pour de plus amples informations, veuillez consulter [the section called "Lecture en parallèle à partir de JDBC"](#).
- "hashpartitions" : (facultatif) un entier positif. Utilisé pour indiquer le nombre de lectures parallèles de la table JDBC lors de la lecture de tables JDBC en parallèle. Par défaut : 7. Pour de plus amples informations, veuillez consulter [the section called "Lecture en parallèle à partir de JDBC"](#).

- "sampleQuery" : (facultatif) une instruction de requête SQL personnalisée. Utilisé pour spécifier un sous-ensemble d'informations dans une table afin de récupérer un échantillon du contenu de la table. Lorsqu'elle est configurée sans tenir compte de vos données, elle peut être moins efficace que DynamicFrame les méthodes, entraînant des délais d'attente ou des erreurs de mémoire insuffisante. Pour de plus amples informations, veuillez consulter [the section called "Utiliser sampleQuery"](#).
- "enablePartitioningForSampleQuery" : (facultatif) une valeur booléenne. Par défaut : faux. Utilisé pour permettre la lecture des tables JDBC en parallèle lorsque vous indiquez sampleQuery. S'il est défini sur true, **sampleQuery** il doit se terminer par « where » ou « and » pour que AWS Glue ajoute des conditions de partitionnement. Pour de plus amples informations, veuillez consulter [the section called "Utiliser sampleQuery"](#).
- "sampleSize" : (facultatif) un entier positif. Limite le nombre de lignes renvoyées par l'exemple de requête. Fonctionne uniquement lorsque enablePartitioningForSampleQuery a la valeur « true ». Si le partitionnement n'est pas activé, vous devez plutôt ajouter directement "limit x" dans sampleQuery pour limiter la taille. Pour de plus amples informations, veuillez consulter [the section called "Utiliser sampleQuery"](#).

Utiliser sampleQuery

Cette section explique comment utiliser sampleQuery, sampleSize et enablePartitioningForSampleQuery.

sampleQuery peut être un moyen efficace d'échantillonner quelques lignes de votre jeu de données. Par défaut, la requête est exécutée par un exécuteur unique. Lorsqu'elle est configurée sans tenir compte de vos données, elle peut être moins efficace que DynamicFrame les méthodes, entraînant des délais d'attente ou des erreurs de mémoire insuffisante. L'exécution de SQL sur la base de données sous-jacente dans le cadre de votre pipeline ETL n'est généralement nécessaire que pour des raisons de performances. Si vous essayez de prévisualiser quelques lignes de votre jeu de données, pensez à utiliser [the section called "show"](#). Si vous essayez de transformer votre ensemble de données à l'aide de SQL, pensez [the section called "toDF"](#) à l'utiliser pour définir une transformation SparkSQL par rapport à vos données dans un formulaire. DataFrame

Bien que votre requête puisse manipuler diverses tables, dbtable reste obligatoire.

Utilisation de sampleQuery pour récupérer un échantillon de votre table

Lorsque vous utilisez le comportement SampleQuery par défaut pour récupérer un échantillon de vos données, AWS Glue ne s'attend pas à un débit important. Il exécute donc votre requête sur un seul

exécuteur. Afin de limiter les données que vous fournissez et de ne pas entraîner de problèmes de performances, nous vous suggérons de fournir une clause LIMIT à SQL.

Exemple Utiliser SampleQuery sans partitionnement

L'exemple de code suivant illustre comment utiliser sampleQuery sans partitionnement.

```
//A full sql query statement.
val query = "select name from $tableName where age > 0 limit 1"
val connectionOptions = JsonOptions(Map(
  "url" -> url,
  "dbtable" -> tableName,
  "user" -> user,
  "password" -> password,
  "sampleQuery" -> query ))
val dyf = glueContext.getSource("mysql", connectionOptions)
    .getDynamicFrame()
```

Utilisation de sampleQuery sur des jeux de données plus volumineux

Si vous lisez un jeu de données volumineux, vous devrez peut-être activer le partitionnement JDBC pour interroger une table en parallèle. Pour de plus amples informations, veuillez consulter [the section called “Lecture en parallèle à partir de JDBC”](#). Pour utiliser sampleQuery avec le partitionnement JDBC, paramétrez enablePartitioningForSampleQuery sur la valeur « true ». L'activation de cette fonctionnalité nécessite que vous apportiez quelques modifications à votre sampleQuery.

Lorsque vous utilisez le partitionnement JDBC avec sampleQuery, votre requête doit se terminer par « where » ou « and » pour que AWS Glue ajoute des conditions de partitionnement.

Si vous souhaitez limiter les résultats de votre sampleQuery lorsque vous lisez des tables JDBC en parallèle, définissez le paramètre "sampleSize" plutôt que d'indiquer une clause LIMIT.

Exemple Utiliser SampleQuery avec le partitionnement JDBC

L'exemple de code suivant illustre comment utiliser sampleQuery avec partitionnement JDBC.

```
//note that the query should end with "where" or "and" if use with JDBC partitioning.
val query = "select name from $tableName where age > 0 and"

//Enable JDBC partitioning by setting hashfield.
//to use sampleQuery with partitioning, set enablePartitioningForSampleQuery.
//use sampleSize to limit the size of returned data.
```

```
val connectionOptions = JsonOptions(Map(
  "url" -> url,
  "dbtable" -> tableName,
  "user" -> user,
  "password" -> password,
  "hashfield" -> primaryKey,
  "sampleQuery" -> query,
  "enablePartitioningForSampleQuery" -> true,
  "sampleSize" -> "1" ))
val dyf = glueContext.getSource("mysql", connectionOptions)
  .getDynamicFrame()
```

Notes et restrictions :

Les exemples de requêtes ne peuvent pas être utilisés avec des signets de tâche. L'état du signet sera ignoré lorsque la configuration sera fournie pour les deux.

Utiliser un pilote JDBC personnalisé

Les exemples de code suivants montrent comment lire et écrire des bases de données JDBC avec des pilotes JDBC personnalisés. Ils présentent la lecture d'une version d'un produit de base de données et l'écriture dans une version ultérieure du même produit.

Python

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext, SparkConf
from awsglue.context import GlueContext
from awsglue.job import Job
import time
from pyspark.sql.types import StructType, StructField, IntegerType, StringType

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

# Construct JDBC connection options
connection_mysql5_options = {
    "url": "jdbc:mysql://<jdbc-host-name>:3306/db",
    "dbtable": "test",
    "user": "admin",
```

```
"password": "pwd"}

connection_mysql8_options = {
    "url": "jdbc:mysql://<jdbc-host-name>:3306/db",
    "dbtable": "test",
    "user": "admin",
    "password": "pwd",
    "customJdbcDriverS3Path": "s3://amzn-s3-demo-bucket/mysql-connector-
java-8.0.17.jar",
    "customJdbcDriverClassName": "com.mysql.cj.jdbc.Driver"}

connection_oracle11_options = {
    "url": "jdbc:oracle:thin:@//<jdbc-host-name>:1521/ORCL",
    "dbtable": "test",
    "user": "admin",
    "password": "pwd"}

connection_oracle18_options = {
    "url": "jdbc:oracle:thin:@//<jdbc-host-name>:1521/ORCL",
    "dbtable": "test",
    "user": "admin",
    "password": "pwd",
    "customJdbcDriverS3Path": "s3://amzn-s3-demo-bucket/ojdbc10.jar",
    "customJdbcDriverClassName": "oracle.jdbc.OracleDriver"}

# Read from JDBC databases with custom driver
df_mysql8 = glueContext.create_dynamic_frame.from_options(connection_type="mysql",

    connection_options=connection_mysql8_options)

# Read DynamicFrame from MySQL 5 and write to MySQL 8
df_mysql5 = glueContext.create_dynamic_frame.from_options(connection_type="mysql",

    connection_options=connection_mysql5_options)
glueContext.write_from_options(frame_or_dfc=df_mysql5, connection_type="mysql",
    connection_options=connection_mysql8_options)

# Read DynamicFrame from Oracle 11 and write to Oracle 18
df_oracle11 =
    glueContext.create_dynamic_frame.from_options(connection_type="oracle",

    connection_options=connection_oracle11_options)
glueContext.write_from_options(frame_or_dfc=df_oracle11, connection_type="oracle",
    connection_options=connection_oracle18_options)
```

Scala

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamicFrame
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {
  val MYSQL_5_URI: String = "jdbc:mysql://<jdbc-host-name>:3306/db"
  val MYSQL_8_URI: String = "jdbc:mysql://<jdbc-host-name>:3306/db"
  val ORACLE_11_URI: String = "jdbc:oracle:thin:@//<jdbc-host-name>:1521/ORCL"
  val ORACLE_18_URI: String = "jdbc:oracle:thin:@//<jdbc-host-name>:1521/ORCL"

  // Construct JDBC connection options
  lazy val mysql5JsonOption = jsonOptions(MYSQL_5_URI)
  lazy val mysql8JsonOption = customJDBCDriverJsonOptions(MYSQL_8_URI, "s3://amzn-s3-demo-bucket/mysql-connector-java-8.0.17.jar", "com.mysql.cj.jdbc.Driver")
  lazy val oracle11JsonOption = jsonOptions(ORACLE_11_URI)
  lazy val oracle18JsonOption = customJDBCDriverJsonOptions(ORACLE_18_URI, "s3://amzn-s3-demo-bucket/ojdbc10.jar", "oracle.jdbc.OracleDriver")

  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    // Read from JDBC database with custom driver
    val df_mysql8: DynamicFrame = glueContext.getSource("mysql",
mysql8JsonOption).getDynamicFrame()

    // Read DynamicFrame from MySQL 5 and write to MySQL 8
    val df_mysql5: DynamicFrame = glueContext.getSource("mysql",
mysql5JsonOption).getDynamicFrame()
    glueContext.getSink("mysql", mysql8JsonOption).writeDynamicFrame(df_mysql5)
```

```
// Read DynamicFrame from Oracle 11 and write to Oracle 18
val df_oracle11: DynamicFrame = glueContext.getSource("oracle",
oracle11JsonOption).getDynamicFrame()
glueContext.getSink("oracle", oracle18JsonOption).writeDynamicFrame(df_oracle11)

Job.commit()
}

private def jsonOptions(url: String): JsonOptions = {
  new JsonOptions(
    s""""{"url": "${url}",
      |"dbtable": "test",
      |"user": "admin",
      |"password": "pwd"}"""".stripMargin)
}

private def customJDBCdriverJsonOptions(url: String, customJdbcDriverS3Path:
String, customJdbcDriverClassName: String): JsonOptions = {
  new JsonOptions(
    s""""{"url": "${url}",
      |"dbtable": "test",
      |"user": "admin",
      |"password": "pwd",
      |"customJdbcDriverS3Path": "${customJdbcDriverS3Path}",
      |"customJdbcDriverClassName" :
"${customJdbcDriverClassName}"}"""".stripMargin)
}
}
```

Lecture en parallèle à partir de tables JDBC

Vous pouvez définir les propriétés de votre table JDBC pour activer AWS Glue pour lire les données en parallèle. Lorsque vous définissez certaines propriétés, vous indiquez AWS Glue pour exécuter des requêtes SQL parallèles sur des partitions logiques de vos données. Vous pouvez contrôler le partitionnement en définissant un champ de hachage ou une expression de hachage. Vous pouvez également contrôler le nombre de lectures parallèles utilisées pour accéder à vos données.

La lecture en parallèle à partir de tables JDBC est une technique d'optimisation susceptible d'améliorer les performances. Pour plus d'informations sur le processus permettant d'identifier le moment où cette technique est appropriée, consultez la section [Réduire la quantité de données](#)

[analysées](#) dans le guide des meilleures pratiques pour le réglage des performances AWS Glue pour les tâches Apache Spark sur les directives AWS prescriptives.

Pour activer les lectures parallèles, vous pouvez définir des paires clé-valeur dans le champ des paramètres de la structure de votre table. Utilisez la notation JSON pour définir une valeur pour le champ des paramètres de votre table. Pour plus d'informations sur la modification des propriétés d'une table, consultez [Afficher et gérer les détails des tables](#). Vous pouvez également activer les lectures parallèles lorsque vous appelez les méthodes d'extraction, de transformation et de chargement (ETL) `create_dynamic_frame_from_options` et `create_dynamic_frame_from_catalog`. Pour plus d'informations sur la spécification d'options dans ces méthodes, consultez [from_options](#) et [from_catalog](#).

Vous pouvez utiliser cette méthode pour les tables JDBC, c'est-à-dire la plupart des tables dont la base de données est un magasin de données JDBC. Ces propriétés sont ignorées lors de la lecture des tables Amazon Redshift et Amazon S3.

hashfield

Définissez `hashfield` sur le nom d'une colonne de la table JDBC à utiliser pour diviser les données en partitions. Pour de meilleurs résultats, cette colonne doit avoir une distribution uniforme des valeurs pour répartir les données entre les partitions. Cette colonne peut contenir n'importe quel type de données. AWS Glue génère des requêtes sans chevauchement qui s'exécutent en parallèle pour lire les données partitionnées par cette colonne. Par exemple, si vos données sont réparties de façon uniforme par mois, vous pouvez utiliser la colonne `month` pour lire chaque mois de données en parallèle.

```
'hashfield': 'month'
```

AWS Glue crée une requête pour hacher la valeur du champ en un numéro de partition et exécute la requête pour toutes les partitions en parallèle. Pour utiliser votre propre requête de partition d'une lecture de table, fournissez un élément `hashexpression` au lieu d'un élément `hashfield`.

hashexpression

Définissez `hashexpression` sur une expression SQL (conforme à la syntaxe du moteur de base de données JDBC) qui renvoie un nombre entier. Une expression simple est le nom de n'importe

quelle colonne numérique du tableau. AWS Glue génère des requêtes SQL pour lire les données JDBC en parallèle en utilisant la WHERE clause `hashexpression in the` pour partitionner les données.

Par exemple, utilisez la colonne numérique `customerID` pour lire les données partitionnées en fonction d'un numéro de client.

```
'hashexpression': 'customerID'
```

Avoir AWS Glue contrôlez le partitionnement, fournissez un `hashfield` au lieu de `a.hashexpression`

`hashpartitions`

Définissez l'élément `hashpartitions` sur le nombre de lectures parallèles de la table JDBC. Si cette propriété n'est pas définie, la valeur par défaut est 7.

Par exemple, définissez le nombre de lectures parallèles de 5 telle sorte que AWS Glue lit vos données avec cinq requêtes (ou moins).

```
'hashpartitions': '5'
```

Configuration d'Amazon VPC pour les connexions JDBC aux magasins de données Amazon RDS à partir de AWS Glue

Lorsque vous utilisez JDBC pour vous connecter à des bases de données dans Amazon RDS, vous devez effectuer une configuration supplémentaire. Pour activer AWS Glue composants pour communiquer avec Amazon RDS, vous devez configurer l'accès à vos magasins de données Amazon RDS dans Amazon VPC. Pour activer AWS Glue pour communiquer entre ses composants, spécifiez un groupe de sécurité doté d'une règle d'autoréférencement entrant pour tous les ports TCP. En créant une règle d'autoréférencement, vous pouvez restreindre la source au même groupe de sécurité dans le VPC. Une règle d'autoréférencement n'ouvrira pas le VPC à tous les réseaux. Le groupe de sécurité par défaut pour votre VPC peut déjà avoir une règle entrante avec référence circulaire pour ALL Traffic.

Pour configurer l'accès entre les magasins de données AWS Glue et Amazon RDS

1. Connectez-vous à la console Amazon RDS AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/rds/> l'adresse.
2. Dans la console Amazon RDS, identifiez le ou les groupes de sécurité utilisés pour contrôler l'accès à votre base de données Amazon RDS.

Dans le volet de navigation de gauche, choisissez Databases, puis sélectionnez l'instance à laquelle vous souhaitez vous connecter dans la liste du volet principal.

Sur la page détaillée de la base de données, recherchez les groupes de sécurité VPC dans l'onglet Connectivité et sécurité.

3. En fonction de l'architecture de votre réseau, identifiez le groupe de sécurité associé qu'il est préférable de modifier pour autoriser l'accès au service AWS Glue. Enregistrez son nom *database-security-group* pour référence future. S'il n'existe aucun groupe de sécurité approprié, suivez les instructions pour [fournir l'accès à votre instance de base de données dans votre VPC en créant un groupe de sécurité](#) dans la documentation Amazon RDS.
4. Connectez-vous à la console Amazon VPC AWS Management Console et ouvrez-la à l'adresse. <https://console.aws.amazon.com/vpc/>
5. Dans la console Amazon VPC, déterminez comment procéder à la mise à jour. *database-security-group*

Dans le volet de navigation de gauche, choisissez Groupes *database-security-group* de sécurité, puis sélectionnez-les dans la liste du volet principal.

6. Identifiez l'ID du groupe de sécurité pour *database-security-group*, *database-sg-id*. Conservez-le pour référence future.

Sur la page détaillée du groupe de sécurité, recherchez l'ID du groupe de sécurité.

7. Modifiez les règles entrantes pour *database-security-group*, ajoutez une règle d'autoréférencement pour autoriser AWS Glue composants pour communiquer. Plus précisément, ajoutez ou confirmez qu'il existe une règle dans laquelle le type est All TCP, le protocole est TCP, la plage de ports inclut tous les ports et la source est *database-sg-id*. Vérifiez que le groupe de sécurité que vous avez saisi pour Source est le même que le groupe de sécurité que vous modifiez.

Sur la page détaillée du groupe de sécurité, sélectionnez Modifier les règles entrantes.

La règle entrante ressemble à ce qui suit :

Type	Protocole	Plage de ports	Source
Tous les TCP	TCP	0-65535	<i>database-sg-id</i>

8. Ajoutez des règles pour le trafic sortant.

Sur la page détaillée du groupe de sécurité, sélectionnez Modifier les règles sortantes.

Si votre groupe de sécurité autorise tout le trafic sortant, vous n'avez pas besoin de règles distinctes. Par exemple :

Type	Protocole	Plage de ports	Destination
Tout le trafic	ALL	ALL	0.0.0.0/0

Si votre architecture réseau est conçue pour vous permettre de restreindre le trafic sortant, créez les règles de trafic sortant suivantes :

Créez une règle d'autoréférencement où le type est `All`, le protocole est `TCP`, la plage de ports inclut tous les ports et la destination est *database-sg-id*. Vérifiez que le groupe de sécurité que vous avez saisi pour Destination est le même que le groupe de sécurité que vous modifiez.

Si vous utilisez un point de terminaison Amazon S3 VPC, ajoutez une règle HTTPS pour autoriser le trafic entre le VPC et Amazon S3. Créez une règle dans laquelle le type est `HTTPS`, le protocole est `TCP`, la plage de ports est `443` et la destination est l'ID de la liste de préfixes gérée pour le point de terminaison de la passerelle Amazon S3, *s3-prefix-list-id*. Pour plus d'informations sur les listes de préfixes et les points de terminaison de passerelle Amazon S3, consultez la section Points de [terminaison de passerelle pour Amazon S3](#) dans la documentation Amazon VPC.

Par exemple :

Type	Protocole	Plage de ports	Destination
Tous les TCP	TCP	0-65535	<i>database-sg-id</i>

Type	Protocole	Plage de ports	Destination
HTTPS	TCP	443	<i>s3-prefix-list-id</i>

Connexions MongoDB

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire dans des tables dans MongoDB et MongoDB Atlas dans AWS Glue 4.0 et versions ultérieures. Vous pouvez vous connecter à MongoDB en utilisant les informations d'identification du nom d'utilisateur et du mot de passe stockées AWS Secrets Manager via une connexion AWS Glue.

Pour plus d'informations sur MongoDB, consultez la [documentation MongoDB](#).

Configuration de connexions MongoDB

Pour vous connecter à MongoDB depuis AWS Glue, vous aurez besoin de vos informations d'identification MongoDB, et. *mongodbUser mongodbPass*

Pour vous connecter à MongoDB depuis AWS Glue, vous aurez peut-être besoin de certaines conditions préalables :

- Si votre instance MongoDB se trouve dans un Amazon VPC, configurez Amazon VPC pour permettre à votre tâche AWS Glue de communiquer avec l'instance MongoDB sans que le trafic ne transite par l'Internet public.

Dans Amazon VPC, identifiez ou créez un VPC, un sous-réseau et un groupe de sécurité que AWS Glue utilisera lors de l'exécution de la tâche. En outre, vous devez vous assurer qu'Amazon VPC est configuré pour autoriser le trafic réseau entre votre instance MongoDB et cet emplacement. Selon la configuration de votre réseau, cela peut nécessiter des modifications des règles du groupe de sécurité, du réseau ACLs, des passerelles NAT et des connexions d'appairage.

Vous pouvez ensuite configurer AWS Glue pour l'utiliser avec MongoDB.

Pour configurer une connexion à MongoDB :

1. Vous pouvez éventuellement créer un secret à AWS Secrets Manager l'aide de vos informations d'identification MongoDB. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager

documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.

- Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé *username* contenant la valeur. *mongodbUser*

Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé *password* contenant la valeur. *mongodbPass*

2. Dans la console AWS Glue, créez une connexion en suivant les étapes décrites dans [the section called "Ajouter une AWS Glue connexion"](#). Après avoir créé la connexion, conservez le nom de la connexion pour une utilisation future dans AWS Glue. *connectionName*

- Lorsque vous sélectionnez un type de connexion, sélectionnez MongoDB ou MongoDB Atlas.
- Lorsque vous sélectionnez une URL MongoDB ou une URL MongoDB Atlas, indiquez le nom d'hôte de votre instance MongoDB.

Une URL MongoDB est fournie au format
mongodb://mongoHost:mongoPort/mongoDBName.

Une URL MongoDB Atlas est fournie au format *mongodb*
+srv://mongoHost:mongoPort/mongoDBName.

La fourniture de la base de données par défaut pour la connexion *mongoDBName* est facultative.

- Si vous avez choisi de créer un secret Secrets Manager, choisissez le type AWS Secrets Manager d'identifiant.

Ensuite, dans AWS Secret, fournissez *secretName*.

- Si vous choisissez de fournir un nom d'utilisateur et un mot de passe, fournissez *mongodbUser* et *mongodbPass*.

3. Dans les situations suivantes, vous pouvez avoir besoin d'une configuration supplémentaire :

- Pour les instances MongoDB hébergées AWS dans un Amazon VPC
 - Vous devrez fournir les informations de connexion Amazon VPC à la connexion AWS Glue qui définit vos informations de sécurité MongoDB. Lorsque vous créez ou mettez à jour votre connexion, définissez le VPC, le sous-réseau et les groupes de sécurité dans les options réseau.

Après avoir créé une connexion AWS Glue MongoDB, vous devez effectuer les actions suivantes avant d'appeler votre méthode de connexion :

- Si vous avez choisi de créer un secret Secrets Manager, accordez au rôle IAM associé à votre tâche AWS Glue l'autorisation de lecture *secretName*.
- Dans la configuration de votre tâche AWS Glue *connectionName*, fournissez une connexion réseau supplémentaire.

Pour utiliser votre connexion AWS Glue MongoDB dans AWS Glue for Spark, indiquez l'*connectionName* option dans votre appel de méthode de connexion. Vous pouvez également suivre les étapes décrites [the section called “Intégration à MongoDB”](#) pour utiliser la connexion en conjonction avec le AWS Glue Data Catalog.

Lecture depuis MongoDB à l'aide d'une connexion Glue AWS

Prérequis :

- Une collection MongoDB à partir de laquelle vous souhaitez lire. Vous aurez besoin des informations d'identification pour la collection.

Une collection MongoDB est identifiée par un nom de base de données et un nom de collection,,*mongodbName.mongodbCollection*

- Une connexion AWS Glue MongoDB configurée pour fournir des informations d'authentification. Suivez les étapes de la procédure précédente Pour configurer une connexion à MongoDB afin de configurer vos informations d'authentification. Vous aurez besoin du nom de la connexion AWS Glue,*connectionName*.

Par exemple :

```
mongodb_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="mongodb",  
    connection_options={  
        "connectionName": "connectionName",  
        "database": "mongodbName",  
        "collection": "mongodbCollection",  
        "partitioner":  
        "com.mongodb.spark.sql.connector.read.partitioners.SinglePartitionPartitioner",  
        "partitionerOptions.partitionSizeMB": "10",  
        "partitionerOptions.partitionKey": "_id",
```

```
        "disableUpdateUri": "false",
    }
)
```

Écrire dans des tables MongoDB

Cet exemple écrit les informations d'un fichier existant DynamicFrame *dynamicFrame* dans MongoDB.

Prérequis :

- Une collection MongoDB sur laquelle vous souhaitez écrire. Vous aurez besoin des informations d'identification pour la collection.

Une collection MongoDB est identifiée par un nom de base de données et un nom de collection, *mongodbName.mongodbCollection*

- Une connexion AWS Glue MongoDB configurée pour fournir des informations d'authentification. Suivez les étapes de la procédure précédente Pour configurer une connexion à MongoDB afin de configurer vos informations d'authentification. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.

Par exemple :

```
glueContext.write_dynamic_frame.from_options(  
    frame=dynamicFrame,  
    connection_type="mongodb",  
    connection_options={  
        "connectionName": "connectionName",  
        "database": "mongodbName",  
        "collection": "mongodbCollection",  
        "disableUpdateUri": "false",  
        "retryWrites": "false",  
    },  
)
```

Lire et écrire dans des tables MongoDB

Cet exemple écrit les informations d'un fichier existant DynamicFrame *dynamicFrame* dans MongoDB.

Prérequis :

- Une collection MongoDB à partir de laquelle vous souhaitez lire. Vous aurez besoin des informations d'identification pour la collection.

Une collection MongoDB sur laquelle vous souhaitez écrire. Vous aurez besoin des informations d'identification pour la collection.

Une collection MongoDB est identifiée par un nom de base de données et un nom de collection,,*mongodbName.mongodbCollection*

- informations d'authentification MongoDB, et. *mongodbUser mongodbPassword*

Par exemple :

Python

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext, SparkConf
from awsglue.context import GlueContext
from awsglue.job import Job
import time

## @params: [JOB_NAME]
args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

job = Job(glueContext)
job.init(args['JOB_NAME'], args)

output_path = "s3://some_bucket/output/" + str(time.time()) + "/"
mongo_uri = "mongodb://<mongo-instanced-ip-address>:27017"
mongo_ssl_uri = "mongodb://<mongo-instanced-ip-address>:27017"
write_uri = "mongodb://<mongo-instanced-ip-address>:27017"

read_mongo_options = {
    "uri": mongo_uri,
    "database": "mongodbName",
    "collection": "mongodbCollection",
    "username": "mongodbUsername",
```

```

    "password": "mongodbPassword",
    "partitioner": "MongoSamplePartitioner",
    "partitionerOptions.partitionSizeMB": "10",
    "partitionerOptions.partitionKey": "_id"}

ssl_mongo_options = {
    "uri": mongo_ssl_uri,
    "database": "mongodbName",
    "collection": "mongodbCollection",
    "ssl": "true",
    "ssl.domain_match": "false"
}

write_mongo_options = {
    "uri": write_uri,
    "database": "mongodbName",
    "collection": "mongodbCollection",
    "username": "mongodbUsername",
    "password": "mongodbPassword",
}

# Get DynamicFrame from MongoDB
dynamic_frame =
    glueContext.create_dynamic_frame.from_options(connection_type="mongodb",

    connection_options=read_mongo_options)

# Write DynamicFrame to MongoDB
glueContext.write_dynamic_frame.from_options(dynamicFrame,
    connection_type="mongodb", connection_options=write_mongo_options)

job.commit()

```

Scala

```

import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamicFrame
import org.apache.spark.SparkContext

```

```

import scala.collection.JavaConverters._

object GlueApp {
  val DEFAULT_URI: String = "mongodb://<mongo-instanced-ip-address>:27017"
  val WRITE_URI: String = "mongodb://<mongo-instanced-ip-address>:27017"
  lazy val defaultJsonOption = jsonOptions(DEFAULT_URI)
  lazy val writeJsonOption = jsonOptions(WRITE_URI)
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    // Get DynamicFrame from MongoDB
    val dynamicFrame: DynamicFrame = glueContext.getSource("mongodb",
defaultJsonOption).getDynamicFrame()

    // Write DynamicFrame to MongoDB
    glueContext.getSink("mongodb", writeJsonOption).writeDynamicFrame(dynamicFrame)

    Job.commit()
  }

  private def jsonOptions(uri: String): JsonOptions = {
    new JsonOptions(
      s""""{"uri": "${uri}",
        |"database": "mongodbName",
        |"collection": "mongodbCollection",
        |"username": "mongodbUsername",
        |"password": "mongodbPassword",
        |"ssl": "true",
        |"ssl.domain_match": "false",
        |"partitioner": "MongoSamplePartitioner",
        |"partitionerOptions.partitionSizeMB": "10",
        |"partitionerOptions.partitionKey": "_id"}"""".stripMargin)
    }
  }
}

```

Référence des options de connexion MongoDB

Désigne une connexion à MongoDB. Les options de connexion sont différentes pour une connexion source et une connexion collecteur.

Les propriétés de connexion suivantes sont partagées entre les connexions source et récepteur :

- `connectionName` : utilisé pour la lecture/l'écriture. Le nom d'une connexion AWS Glue MongoDB configurée pour fournir des informations d'authentification et de mise en réseau à votre méthode de connexion. Lorsqu'une connexion AWS Glue est configurée comme décrit dans la section précédente [the section called "Configuration de MongoDB"](#), la fourniture `connectionName` remplacera le besoin de fournir `"uri"` les options `"username"` et de `"password"` connexion.
- `"uri"` : (Obligatoire) L'hôte MongoDB à lire, formaté comme `mongodb://<host>:<port>`. Utilisé dans les versions de AWS Glue antérieures à AWS Glue 4.0.
- `"connection.uri"` : (Obligatoire) L'hôte MongoDB à lire, formaté comme `mongodb://<host>:<port>`. Utilisé dans AWS Glue 4.0 et versions ultérieures.
- `"username"` : (Obligatoire) Le nom d'utilisateur MongoDB.
- `"password"` : (Obligatoire) Le mot de passe MongoDB.
- `"database"` : (Obligatoire) La base de données MongoDB à lire. Cette option peut également être transmise dans `additional_options` lors de l'appel à `glue_context.create_dynamic_frame_from_catalog` dans votre script de tâche.
- `"collection"` : (Obligatoire) La collection MongoDB à lire. Cette option peut également être transmise dans `additional_options` lors de l'appel à `glue_context.create_dynamic_frame_from_catalog` dans votre script de tâche.

« `connectionType` »: « `mongodb` » comme source

Utilisez les options de connexion suivantes avec `"connectionType"`: `"mongodb"` comme source :

- `"ssl"` : (Facultatif) Si `true`, lance une connexion SSL. L'argument par défaut est `false`.
- `"ssl.domain_match"` : (Facultatif) Si `true` et `ssl` est `true`, la vérification de la correspondance de domaine est effectuée. L'argument par défaut est `true`.
- `"batchSize"` : (Facultatif) : Nombre de documents à renvoyer par lot, utilisé dans le curseur des lots internes.
- `"partitioner"` : (Facultatif) : Le nom de classe du partitionneur pour lire les données d'entrée de MongoDB. Le connecteur fournit les partitionneurs suivants :
 - `MongoDefaultPartitioner` (par défaut) (Non pris en charge dans AWS Glue 4.0)
 - `MongoSamplePartitioner` (Nécessite MongoDB 3.2 ou version ultérieure) (Non pris en charge dans AWS Glue 4.0)

- `MongoShardedPartitioner`(Non pris en charge dans AWS Glue 4.0)
- `MongoSplitVectorPartitioner`(Non pris en charge dans AWS Glue 4.0)
- `MongoPaginateByCountPartitioner`(Non pris en charge dans AWS Glue 4.0)
- `MongoPaginateBySizePartitioner`(Non pris en charge dans AWS Glue 4.0)
- `com.mongodb.spark.sql.connector.read.partitionner.SinglePartitionPartitioner`
- `com.mongodb.spark.sql.connector.read.partitionner.ShardedPartitioner`
- `com.mongodb.spark.sql.connector.read.partitionner.PaginateIntoPartitionsPartitioner`
- `"partitionerOptions"` (Facultatif) : Options pour le partitionneur désigné. Les options suivantes sont prises en charge pour chaque partitionneur :
 - `MongoSamplePartitioner`: `partitionKey`, `partitionSizeMB`, `samplesPerPartition`
 - `MongoShardedPartitioner`: `shardkey`
 - `MongoSplitVectorPartitioner`: `partitionKey`, `partitionSizeMB`
 - `MongoPaginateByCountPartitioner`: `partitionKey`, `numberOfPartitions`
 - `MongoPaginateBySizePartitioner`: `partitionKey`, `partitionSizeMB`

Pour plus d'informations sur ces options, consultez [Configuration du partitionneur](#) dans la documentation MongoDB.

« `connectionType` »: « `mongodb` » comme collecteur

Utilisez les options de connexion suivantes avec `"connectionType": "mongodb"` comme collecteur :

- `"ssl"` : (Facultatif) Si `true`, lance une connexion SSL. L'argument par défaut est `false`.
- `"ssl.domain_match"` : (Facultatif) Si `true` et `ssl` est `true`, la vérification de la correspondance de domaine est effectuée. L'argument par défaut est `true`.
- `"extendedBsonTypes"` : (facultatif) si la valeur est `true`, cela active les types BSON étendus lors de l'écriture de données dans MongoDB. L'argument par défaut est `true`.
- `"replaceDocument"` : (Facultatif) Si `true`, remplace l'ensemble du document lors de l'enregistrement de jeux de données contenant un champ `_id`. Si `false`, seuls les champs du document qui correspondent aux champs du jeu de données sont mis à jour. L'argument par défaut est `true`.
- `"maxBatchSize"` : (Facultatif) : Taille maximale du lot pour les opérations en bloc lors de l'enregistrement des données. La valeur par défaut est 512.

- "retryWrites": (Facultatif) : Réessayez automatiquement certaines opérations d'écriture une seule fois si AWS Glue rencontre une erreur réseau.

Connexions SAP HANA

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire dans des tables dans SAP HANA dans AWS Glue 4.0 et versions ultérieures. Vous pouvez définir ce qu'il faut lire dans SAP HANA à l'aide d'une requête SQL. Vous vous connectez à SAP HANA à l'aide des informations d'identification JDBC stockées via AWS Secrets Manager une connexion AWS Glue SAP HANA.

Pour plus d'informations sur SAP HANA JDBC, consultez [la documentation SAP HANA](#).

Configuration des connexions SAP HANA

Pour vous connecter à SAP HANA depuis AWS Glue, vous devez créer et stocker vos informations d'identification SAP HANA dans un AWS Secrets Manager secret, puis associer ce secret à une connexion SAP HANA AWS Glue. Vous devrez configurer la connectivité réseau entre votre service SAP HANA et AWS Glue.

Pour vous connecter à SAP HANA, vous aurez peut-être besoin de certaines conditions préalables :

- Si votre service SAP HANA se trouve dans un Amazon VPC, configurez Amazon VPC pour permettre à votre tâche AWS Glue de communiquer avec le service SAP HANA sans que le trafic ne transite par l'Internet public.

Dans Amazon VPC, identifiez ou créez un VPC, un sous-réseau et un groupe de sécurité que AWS Glue utilisera lors de l'exécution de la tâche. En outre, vous devez vous assurer qu'Amazon VPC est configuré pour autoriser le trafic réseau entre votre point de terminaison SAP HANA et cet emplacement. Votre tâche devra établir une connexion TCP avec votre port JDBC SAP HANA. Pour plus d'informations sur les ports SAP HANA, consultez [la documentation SAP HANA](#). Selon la configuration de votre réseau, cela peut nécessiter des modifications des règles du groupe de sécurité, du réseau ACLs, des passerelles NAT et des connexions d'appairage.

- Il n'y a aucune condition préalable supplémentaire si votre point de terminaison SAP HANA est accessible sur Internet.

Pour configurer une connexion à SAP HANA :

1. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification SAP HANA. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la

[section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation.

Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.

- Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé `user` contenant la valeur. *saphanaUsername*
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé `password` contenant la valeur. *saphanaPassword*
2. Dans la console AWS Glue, créez une connexion en suivant les étapes décrites dans [the section called "Ajouter une AWS Glue connexion"](#). Après avoir créé la connexion, conservez le nom de la connexion pour une utilisation future dans AWS Glue. *connectionName*
- Lorsque vous sélectionnez un type de connexion, sélectionnez SAP HANA.
 - Lorsque vous fournissez l'URL SAP HANA, indiquez l'URL de votre instance.

SAP HANA JDBC se présente sous la URLs forme

`jdbc:sap://saphanaHostname:saphanaPort/?databaseName=saphanaDBname,Paramete`

AWS Glue nécessite les paramètres d'URL JDBC suivants :

- `databaseName` – une base de données par défaut dans SAP HANA à laquelle se connecter.
- Lorsque vous sélectionnez un AWS secret, fournissez *secretName*.

Après avoir créé une connexion AWS Glue SAP HANA, vous devez suivre les étapes suivantes avant d'exécuter votre tâche AWS Glue :

- Accordez au rôle IAM associé à votre tâche AWS Glue l'autorisation de lire *secretName*.
- Dans la configuration de votre tâche AWS Glue *connectionName*, fournissez une connexion réseau supplémentaire.

Lecture à partir de tables SAP HANA

Prérequis :

- Une table SAP HANA à partir de laquelle vous souhaitez lire. Vous aurez besoin des informations d'identification de la table.

Une table peut être spécifiée avec un nom de table SAP HANA et un nom de schéma, sous forme de *schemaName.tableName*. Le nom du schéma et le séparateur « . » ne sont pas obligatoires si la table se trouve dans le schéma par défaut, « public ». Appelle ça *tableIdentifier*. Notez que la base de données est fournie sous forme de paramètre d'URL JDBC dans *connectionName*.

- Une connexion AWS Glue SAP HANA configurée pour fournir des informations d'authentification. Suivez les étapes de la procédure précédente Pour configurer une connexion à SAP HANA afin de configurer vos informations d'authentification. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.

Par exemple :

```
saphana_read_table = glueContext.create_dynamic_frame.from_options(  
    connection_type="saphana",  
    connection_options={  
        "connectionName": "connectionName",  
        "dbtable": "tableIdentifier",  
    }  
)
```

Vous pouvez également fournir une requête SQL SELECT pour filtrer les résultats renvoyés à votre DynamicFrame. Vous devrez configurer *query*.

Par exemple :

```
saphana_read_query = glueContext.create_dynamic_frame.from_options(  
    connection_type="saphana",  
    connection_options={  
        "connectionName": "connectionName",  
        "query": "query"  
    }  
)
```

Écrire dans des tables SAP HANA

Cet exemple écrit les informations d'un fichier existant DynamicFrame *dynamicFrame* dans SAP HANA. Si le tableau contient déjà des informations, AWS Glue génère une erreur.

Prérequis :

- Une table SAP HANA dans laquelle vous souhaitez écrire.

Une table peut être spécifiée avec un nom de table SAP HANA et un nom de schéma, sous forme de *schemaName.tableName*. Le nom du schéma et le séparateur « . » ne sont pas obligatoires si la table se trouve dans le schéma par défaut, « public ». Appelle ça *tableIdentifier*. Notez que la base de données est fournie sous forme de paramètre d'URL JDBC dans *connectionName*.

- Informations d'authentification SAP HANA. Suivez les étapes de la procédure précédente Pour configurer une connexion à SAP HANA afin de configurer vos informations d'authentification. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.

Par exemple :

```
options = {  
    "connectionName": "connectionName",  
    "dbtable": 'tableIdentifier'  
}  
  
saphana_write = glueContext.write_dynamic_frame.from_options(  
    frame=dynamicFrame,  
    connection_type="saphana",  
    connection_options=options  
)
```

Référence des options de connexion de SAP HANA

- *connectionName* — Obligatoire. Utilisé pour la lecture/l'écriture. Nom d'une connexion AWS Glue SAP HANA configurée pour fournir des informations d'authentification et de mise en réseau à votre méthode de connexion.
- *databaseName* : utilisé pour la lecture/l'écriture. Valeurs valides : noms des bases de données dans SAP HANA. Nom de base de données à laquelle se connecter.
- *dbtable* — obligatoire pour l'écriture, obligatoire pour la lecture à moins qu'une query ne soit fournie. Utilisé pour la lecture/l'écriture. Valeurs valides : contenu d'une clause SAP HANA SQL FROM. Identifie une table dans SAP HANA à laquelle se connecter. Vous pouvez également fournir un SQL autre qu'un nom de table, comme une sous-requête. Pour plus d'informations, consultez la [clause From](#) dans la documentation SAP HANA.
- *query* : utilisé pour la lecture. Une requête SAP HANA SQL SELECT définissant ce qui doit être récupéré lors de la lecture à partir de SAP HANA.

Connexions Snowflake

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire dans des tables dans Snowflake dans AWS Glue 4.0 et versions ultérieures. Vous pouvez lire depuis Snowflake à l'aide d'une requête SQL. Vous pouvez vous connecter à Snowflake à l'aide d'un nom d'utilisateur et d'un mot de passe. Vous pouvez vous référer aux informations d'identification Snowflake stockées dans le catalogue AWS Secrets Manager de données AWS Glue. Les informations d'identification Snowflake du catalogue de données pour AWS Glue for Spark sont stockées séparément des informations d'identification du catalogue de données Snowflake pour les robots d'exploration. Vous devez choisir un type de connexion SNOWFLAKE et non un type de connexion JDBC configuré pour se connecter à Snowflake.

Pour en savoir plus sur Snowflake, consultez le [site web Snowflake](#). Pour plus d'informations sur Snowflake on AWS, consultez [Snowflake Data Warehouse sur Amazon Web Services](#).

Configuration des connexions Snowflake

Il n'y a aucune AWS condition préalable pour se connecter aux bases de données Snowflake disponibles sur Internet.

Vous pouvez éventuellement effectuer la configuration suivante pour gérer vos informations de connexion avec AWS Glue.

Pour gérer vos informations de connexion avec AWS Glue

1. Dans Snowflake, générez un utilisateur *snowflakeUser* et un mot de passe. *snowflakePassword*
2. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification Snowflake. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour *snowflakeUser* avec la clé. USERNAME
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour *snowflakePassword* avec la clé. PASSWORD
 - Lorsque vous sélectionnez des paires clé/valeur, vous pouvez fournir à votre entrepôt Snowflake la clé sfWarehouse.

3. Dans le catalogue de données AWS Glue, créez une connexion en choisissant **Connections**, puis **Create connection**. Suivez les étapes de l'assistant de connexion pour terminer le processus :
 - Lorsque vous sélectionnez une source de données, sélectionnez **Snowflake**, puis **Next**.
 - Entrez les détails de connexion tels que l'hôte et le port. Lorsque vous entrez l'URL Snowflake de l'hôte, indiquez l'URL de votre instance Snowflake. L'URL utilise généralement un nom d'hôte dans le formulaire `account_identifier.snowflakecomputing.com`. Cependant, le format de l'URL peut varier en fonction du type de compte Snowflake (par exemple AWS, Azure ou hébergé par Snowflake).
 - Lorsque vous sélectionnez le rôle de service IAM, choisissez-le dans le menu déroulant. Il s'agit du rôle IAM de votre compte qui sera utilisé pour accéder à l'adresse IP AWS Secrets Manager et l'attribuer si un VPC est spécifié.
 - Lorsque vous sélectionnez un AWS secret, indiquez-le `secretName`.
4. À l'étape suivante de l'assistant, définissez les propriétés de votre connexion Snowflake.
5. Dans la dernière étape de l'assistant, passez en revue vos paramètres, puis terminez le processus de création de votre connexion.

Dans les situations suivantes, vous pouvez avoir besoin des éléments suivants :

- Pour Snowflake hébergé sur un Amazon AWS VPC
 - Vous aurez besoin d'une configuration Amazon VPC appropriée pour Snowflake. Pour plus d'informations sur la configuration de votre Amazon VPC, consultez [AWS PrivateLink et Snowflake](#) dans la documentation Snowflake.
 - Vous aurez besoin d'une configuration Amazon VPC appropriée pour Glue AWS . [the section called "Configuration des points de terminaison VPC de l'interface \(\) pour AWS PrivateLinkAWS Glue"](#).
 - Vous devrez créer une connexion AWS Glue Data Catalog qui fournit les informations de connexion Amazon VPC (en plus de l'identifiant d'un AWS Secrets Manager secret qui définit vos informations de sécurité Snowflake). Votre URL changera lors de l'utilisation AWS PrivateLink, comme décrit dans la documentation Snowflake dont le lien figure dans un article précédent.
 - Vous aurez besoin de la configuration de votre tâche pour inclure la connexion au catalogue de données en tant que connexion réseau supplémentaire.

Lecture à partir de tables Snowflake

Conditions préalables : une table Snowflake à partir de laquelle vous souhaitez lire. Vous aurez besoin du nom de la table Snowflake, *tableName*. Vous aurez besoin de votre URL *snowflakeUrl*, nom d'utilisateur *snowflakeUser* et mot de passe Snowflake. *snowflakePassword*. Si aucun espace de noms par défaut n'est défini pour votre utilisateur Snowflake, vous aurez besoin du nom de la base de données Snowflake et du nom du schéma. *databaseName* *schemaName*. De plus, si votre utilisateur Snowflake n'a pas défini d'entrepôt par défaut, vous aurez besoin d'un nom d'entrepôt. *warehouseName*.

Par exemple :

Conditions préalables supplémentaires : suivez les étapes pour gérer vos informations d'identification de connexion avec AWS Glue pour les configurer *snowflakeUrl*, *snowflakeUsername* et *snowflakePassword*. Pour passer en revue ces étapes, reportez-vous à la section précédente, [the section called "Configuration de Snowflake"](#). Pour sélectionner la connexion réseau supplémentaire à laquelle se connecter, nous utiliserons le paramètre *connectionName*.

```
snowflake_read = glueContext.create_dynamic_frame.from_options(  
    connection_type="snowflake",  
    connection_options={  
        "connectionName": "connectionName",  
        "dbtable": "tableName",  
        "sfDatabase": "databaseName",  
        "sfSchema": "schemaName",  
        "sfWarehouse": "warehouseName",  
    }  
)
```

De plus, vous pouvez utiliser les paramètres *autopushdown* et *query* pour lire une partie d'une table Snowflake. Cela peut être nettement plus efficace que de filtrer vos résultats une fois qu'ils ont été chargés dans Spark. Prenons un exemple où toutes les ventes sont stockées dans la même table, mais où vous n'avez besoin d'analyser que les ventes d'un certain magasin pendant les jours fériés. Si ces informations sont stockées dans la table, vous pouvez utiliser le *pushdown* de prédicat pour récupérer les résultats comme suit :

```
snowflake_node = glueContext.create_dynamic_frame.from_options(  
    connection_type="snowflake",  
    connection_options={  
        "autopushdown": "on",  
    }
```

```
"query": "select * from sales where store='1' and IsHoliday='TRUE'",
"connectionName": "snowflake-glue-conn",
"sfDatabase": "databaseName",
"sfSchema": "schemaName",
"sfWarehouse": "warehouseName",
}
)
```

Écrire sur les tables Snowflake

Conditions préalables : une base de données Snowflake sur laquelle vous souhaitez écrire.

Vous aurez besoin d'un nom de table actuel ou souhaité, *tableName*. Vous aurez besoin de votre URL *snowflakeUrl*, nom d'utilisateur *snowflakeUser* et mot de passe Snowflake.

snowflakePassword Si aucun espace de noms par défaut n'est défini pour votre utilisateur Snowflake, vous aurez besoin du nom de la base de données Snowflake et du nom du schéma.

databaseName *schemaName* De plus, si votre utilisateur Snowflake n'a pas défini d'entrepôt par défaut, vous aurez besoin d'un nom d'entrepôt. *warehouseName*

Par exemple :

Conditions préalables supplémentaires : suivez les étapes pour gérer vos informations d'identification de connexion avec AWS Glue pour les configurer *snowflakeUrl*, *snowflakeUsername* et *snowflakePassword*. Pour passer en revue ces étapes, reportez-vous à la section précédente, [the section called “Configuration de Snowflake”](#). Pour sélectionner la connexion réseau supplémentaire à laquelle se connecter, nous utiliserons le paramètre *connectionName*.

```
glueContext.write_dynamic_frame.from_options(
    connection_type="snowflake",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableName",
        "sfDatabase": "databaseName",
        "sfSchema": "schemaName",
        "sfWarehouse": "warehouseName",
    },
)
```

Référence des options de connexion Snowflake

Le type de connexion Snowflake accepte les options de connexion suivantes :

Vous pouvez récupérer certains paramètres de cette section à partir d'une connexion au catalogue de données (`sfUrl`, `sfUser`, `sfPassword`), auquel cas vous n'êtes pas obligé de les fournir. Pour ce faire, fournissez le paramètre `connectionName`.

Vous pouvez récupérer certains paramètres de cette section à partir d'un AWS Secrets Manager code secret (`sfUser`, `sfPassword`), auquel cas vous n'êtes pas obligé de les fournir. Le secret doit fournir le contenu situé sous les clés `sfUser` et `sfPassword`. Pour ce faire, fournissez le paramètre `secretId`.

Les paramètres suivants sont généralement utilisés lors de la connexion à Snowflake.

- `sfDatabase` : obligatoire si aucune valeur par défaut de l'utilisateur n'est définie dans Snowflake. Utilisé pour la lecture/l'écriture. La base de données à utiliser pour la session après la connexion.
- `sfSchema` : obligatoire si aucune valeur par défaut de l'utilisateur n'est définie dans Snowflake. Utilisé pour la lecture/l'écriture. Le schéma à utiliser pour la session après la connexion.
- `sfWarehouse` : obligatoire si aucune valeur par défaut de l'utilisateur n'est définie dans Snowflake. Utilisé pour la lecture/l'écriture. L'entrepôt virtuel par défaut à utiliser pour la session après la connexion.
- `sfRole` : obligatoire si aucune valeur par défaut de l'utilisateur n'est définie dans Snowflake. Utilisé pour la lecture/l'écriture. Le rôle de sécurité par défaut à utiliser pour la session après la connexion.
- `sfUrl` : (obligatoire) utilisé pour la lecture/l'écriture. Indique le nom d'hôte de votre compte au format suivant : `account_identifieur.snowflakecomputing.com`. Pour plus d'informations sur les identifiants de compte, consultez [Identifiants de compte](#) dans la documentation de Snowflake.
- `sfUser` : (obligatoire) utilisé pour la lecture/l'écriture. Nom de connexion de l'utilisateur Snowflake.
- `sfPassword` : (Obligatoire sauf si la clé `pem_private_key` est fournie) utilisé pour la lecture/l'écriture. Mot de passe de l'utilisateur Snowflake.
- `dbtable` : obligatoire lorsque vous travaillez avec des tables complètes. Utilisé pour la lecture/l'écriture. Le nom de la table à lire ou de la table dans laquelle les données sont écrites. Lors de la lecture, toutes les colonnes et tous les enregistrements sont récupérés.
- `pem_private_key` : utilisé pour la lecture/l'écriture. Chaîne de clé privée codée en b64 non chiffrée. Clé privée de l'utilisateur Snowflake. Il est courant de la copier à partir d'un fichier PEM. Pour plus d'informations, consultez [Authentification par paire de clés et rotation des paires de clés](#) dans la documentation Snowflake.
- `query` : obligatoire lors de la lecture avec une requête. Utilisé pour la lecture. La requête exacte (instruction `SELECT`) à exécuter

Les options suivantes sont utilisées pour configurer des comportements spécifiques lors du processus de connexion à Snowflake.

- **preactions** : utilisé pour la lecture/l'écriture. Valeurs valides : liste d'instructions SQL séparées par des points-virgules sous forme de chaîne. Les instructions SQL sont exécutées avant le transfert des données entre AWS Glue et Snowflake. Si une instruction contient %s, %s est remplacé par le nom de table référencé pour l'opération.
- **postactions** : utilisé pour la lecture/l'écriture. Les instructions SQL sont exécutées après le transfert des données entre AWS Glue et Snowflake. Si une instruction contient %s, %s est remplacé par le nom de table référencé pour l'opération.
- **autopushdown** : "on" par défaut. Valeurs valides : "on", "off". Ce paramètre contrôle si le pushdown automatique des requêtes est activé. Lorsque l'option pushdown est activée, si une partie de la requête peut être « poussée vers le bas » sur le serveur Snowflake, elle est poussée vers le bas au moment de l'exécution de la requête sur Spark. Cela améliore les performances de certaines requêtes. Pour savoir si votre requête peut être poussée vers le bas, consultez [Pushdown](#) dans la documentation de Snowflake.

En outre, certaines des options disponibles sur le connecteur Snowflake Spark peuvent être prises en charge dans Glue AWS . Pour plus d'informations sur les options disponibles sur le connecteur Snowflake Spark, consultez la section [Réglage des options de configuration du connecteur](#) dans la documentation Snowflake.

Limites du connecteur Snowflake

La connexion à Snowflake avec AWS Glue for Spark est soumise aux restrictions suivantes.

- Ce connecteur ne prend pas en charge les signets de tâches. Pour plus d'informations sur les signets de tâche, consultez [the section called “Suivi des données traitées à l'aide de signets de tâche”](#).
- Ce connecteur ne prend pas en charge les lectures et écritures Snowflake via les tables du catalogue de données AWS Glue à l'aide des méthodes `create_dynamic_frame.from_catalog` et `write_dynamic_frame.from_catalog`.
- Ce connecteur ne prend pas en charge la connexion à Snowflake avec des informations d'identification autres que l'utilisateur et le mot de passe.
- Ce connecteur n'est pas pris en charge dans les tâches de streaming.

- Ce connecteur prend en charge les requêtes basées sur des instructions SELECT lors de la récupération d'informations (par exemple avec le paramètre query). Les autres types de requêtes (telles que SHOW, DESC ou les instructions DML) ne sont pas pris en charge.
- Snowflake limite la taille du texte de la requête (c'est-à-dire les instructions SQL) soumis par les clients Snowflake à 1 Mo par instruction. Pour plus d'informations, consultez [Limites de la taille du texte de requête](#).

Connexions Teradata Vantage

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire dans des tables existantes dans Teradata Vantage dans AWS Glue 4.0 et versions ultérieures. Vous pouvez définir ce qu'il faut lire dans Teradata à l'aide d'une requête SQL. Vous pouvez vous connecter à Teradata à l'aide du nom d'utilisateur et du mot de passe enregistrés AWS Secrets Manager via une connexion AWS Glue.

Pour de plus amples informations sur Teradata, veuillez consulter la [documentation Teradata](#)

Configuration de connexions Teradata

Pour vous connecter à Teradata depuis AWS Glue, vous devez créer et stocker vos informations d'identification Teradata dans un AWS Secrets Manager secret, puis associer ce secret à une connexion AWS Glue Teradata. Si votre instance Teradata se trouve dans un Amazon VPC, vous devrez également fournir des options réseau à votre connexion AWS Glue Teradata.

Pour vous connecter à Teradata depuis AWS Glue, vous aurez peut-être besoin de certaines conditions préalables :

- Si vous accédez à votre environnement Teradata via Amazon VPC, configurez Amazon VPC pour permettre à votre tâche AWS Glue de communiquer avec l'environnement Teradata. Nous vous déconseillons d'accéder à l'environnement Teradata via l'Internet public.

Dans Amazon VPC, identifiez ou créez un VPC, un sous-réseau et un groupe de sécurité que AWS Glue utilisera lors de l'exécution de la tâche. En outre, vous devez vous assurer qu'Amazon VPC est configuré pour autoriser le trafic réseau entre votre instance Teradata et cet emplacement. Votre tâche devra établir une connexion TCP avec votre port client Teradata. Pour de plus amples informations sur les ports Teradata, consultez la [documentation Teradata](#).

Selon la configuration de votre réseau, la connectivité VPC sécurisée peut nécessiter des modifications dans Amazon VPC et dans d'autres services réseau. Pour plus d'informations sur AWS la connectivité, consultez [les options de AWS connectivité](#) dans la documentation Teradata.

Pour configurer une connexion AWS Glue Teradata :

1. Dans votre configuration Teradata, identifiez ou créez un utilisateur et un mot de passe auxquels AWS Glue se connectera, *teradataUser* et *teradataPassword*. Pour plus d'informations, consultez la [présentation de Vantage Security](#) dans la documentation Teradata.
2. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification Teradata. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé user contenant la valeur. *teradataUsername*
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé password contenant la valeur. *teradataPassword*
3. Dans la console AWS Glue, créez une connexion en suivant les étapes décrites dans [the section called "Ajouter une AWS Glue connexion"](#). Après avoir créé la connexion, conservez le nom de la connexion pour l'étape suivante. *connectionName*
 - Lorsque vous sélectionnez un type de connexion, sélectionnez Teradata.
 - Lorsque vous fournissez l'URL JDBC, indiquez l'URL de votre instance. Vous pouvez également coder en dur certains paramètres de connexion séparés par des virgules dans votre URL JDBC. L'URL doit être conforme au format suivant :
`jdbc:teradata://teradataHostname/ParameterName=ParameterValue,ParameterName`

Les paramètres d'URL pris en charge sont les suivants :

 - DATABASE – nom de la base de données sur l'hôte à laquelle accéder par défaut.
 - DBS_PORT – le port de base de données utilisé lors de l'exécution sur un port non standard.
 - Lorsque vous sélectionnez un type d'identifiant, sélectionnez AWS Secrets Manager, puis définissez AWS Secret sur *secretName*.
4. Dans les situations suivantes, vous pouvez avoir besoin d'une configuration supplémentaire :
 - Pour les instances Teradata hébergées sur AWS un Amazon VPC
 - Vous devrez fournir les informations de connexion Amazon VPC à la connexion AWS Glue qui définit vos informations de sécurité Teradata. Lorsque vous créez ou mettez à jour votre connexion, définissez le VPC, le sous-réseau et les groupes de sécurité dans les options réseau.

Après avoir créé une connexion AWS Glue Teradata, vous devez effectuer les étapes suivantes avant d'appeler votre méthode de connexion.

- Accordez au rôle IAM associé à votre tâche AWS Glue l'autorisation de lire *secretName*.
- Dans la configuration de votre tâche AWS Glue *connectionName*, fournissez une connexion réseau supplémentaire.

Lecture à partir de Teradata

Prérequis :

- Une table Teradata à partir de laquelle vous souhaitez lire. Vous aurez besoin du nom de la table, *tableName*.
- Une connexion AWS Glue Teradata configurée pour fournir des informations d'authentification. Suivez les étapes pour configurer une connexion à Teradata afin de configurer vos informations d'authentification. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.

Par exemple :

```
teradata_read_table = glueContext.create_dynamic_frame.from_options(  
    connection_type="teradata",  
    connection_options={  
        "connectionName": "connectionName",  
        "dbtable": "tableName"  
    }  
)
```

Vous pouvez également fournir une requête SQL SELECT pour filtrer les résultats renvoyés à votre DynamicFrame. Vous devrez configurer *query*.

Par exemple :

```
teradata_read_query = glueContext.create_dynamic_frame.from_options(  
    connection_type="teradata",  
    connection_options={  
        "connectionName": "connectionName",  
        "query": "query"  
    }  
)
```

Écrire dans les tables Teradata

Prérequis : une table Teradata dans laquelle vous souhaitez écrire, *tableName* Vous devez créer la table avant d'appeler la méthode de connexion.

Par exemple :

```
teradata_write = glueContext.write_dynamic_frame.from_options(  
    connection_type="teradata",  
    connection_options={  
        "connectionName": "connectionName",  
        "dbtable": "tableName"  
    }  
)
```

Référence des options de connexion Teradata

- `connectionName` — Obligatoire. Utilisé pour la lecture/l'écriture. Nom d'une connexion AWS Glue Teradata configurée pour fournir des informations d'authentification et de mise en réseau à votre méthode de connexion.
- `dbtable` — obligatoire pour l'écriture, obligatoire pour la lecture à moins qu'une query ne soit fournie. Utilisé pour la lecture/l'écriture. Le nom de la table avec laquelle votre méthode de connexion va interagir.
- `query` : utilisé pour la lecture. Une requête SELECT SQL définissant ce qui doit être récupéré lors de la lecture à partir de Teradata.

Connexions Teradata Vantage NOS

La connexion Teradata NOS (Native Object Store) est une nouvelle connexion pour Teradata Vantage qui utilise la requête Teradata WRITE_NOS pour lire des tables existantes et la requête READ_NOS pour écrire dans des tables. Ces requêtes utilisent Amazon S3 comme répertoire intermédiaire. Le connecteur Teradata NOS est donc plus rapide que le connecteur Teradata existant (basé sur JDBC), en particulier lorsqu'il s'agit de gérer de grandes quantités de données.

Vous pouvez utiliser la connexion Teradata NOS dans Spark AWS Glue pour lire et écrire dans des tables existantes dans Teradata Vantage dans les AWS Glue versions 5.0 et ultérieures. Vous pouvez définir ce qu'il faut lire dans Teradata à l'aide d'une requête SQL. Vous pouvez vous connecter à Teradata à l'aide des identifiants de nom d'utilisateur et de mot de passe enregistrés AWS Secrets Manager via une AWS Glue connexion.

Pour plus d'informations sur Teradata, consultez la documentation [Teradata](#).

Rubriques

- [Création d'une connexion Teradata NOS](#)
- [Lecture à partir de tables Teradata](#)
- [Écrire dans les tables Teradata](#)
- [Référence des options de connexion Teradata](#)
- [Fournir des options dans l'interface utilisateur AWS Glue Visual ETL](#)

Création d'une connexion Teradata NOS

Pour vous connecter à Teradata NOS depuis AWS Glue, vous devez créer et stocker vos informations d'identification Teradata dans un AWS Secrets Manager secret, puis associer ce secret à une connexion AWS Glue Teradata NOS. Si votre instance Teradata se trouve dans un Amazon VPC, vous devrez également fournir des options réseau à AWS Glue votre connexion Teradata NOS.

Prérequis :

- Si vous accédez à votre environnement Teradata via Amazon VPC, configurez Amazon VPC pour permettre à AWS Glue votre tâche de communiquer avec l'environnement Teradata. Nous vous déconseillons d'accéder à l'environnement Teradata via l'Internet public.
- Dans Amazon VPC, identifiez ou créez un VPC, un sous-réseau et un groupe de sécurité qui AWS Glue seront utilisés lors de l'exécution de la tâche. En outre, vous devez vous assurer qu'Amazon VPC est configuré pour autoriser le trafic réseau entre votre instance Teradata et cet emplacement. Votre tâche devra établir une connexion TCP avec votre port client Teradata. Pour plus d'informations sur les ports Teradata, consultez les [groupes de sécurité pour Teradata](#) Vantage.
- Selon la configuration de votre réseau, la connectivité VPC sécurisée peut nécessiter des modifications dans Amazon VPC et dans d'autres services réseau. Pour plus d'informations sur AWS la connectivité, consultez la section [Options de AWS connectivité](#) dans la documentation Teradata.

Pour configurer une connexion AWS Glue Teradata NOS :

1. Dans votre configuration Teradata, identifiez ou créez un *teradataUsername* et auquel *teradataPassword* AWS Glue vous vous connecterez. Pour plus d'informations, consultez la [présentation de Vantage Security](#) dans la documentation Teradata.
2. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification Teradata. Pour créer un secret dans AWS Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret dans la AWS Secrets Manager documentation](#). Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé USERNAME avec la valeur. *teradataUsername*
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé PASSWORD avec la valeur. *teradataPassword*
3. Dans la AWS Glue console, créez une connexion en suivant les étapes décrites dans [Ajouter une AWS Glue connexion](#). Après avoir créé la connexion, conservez le nom de la connexion pour l'étape suivante. *connectionName*
 - Lorsque vous sélectionnez un type de connexion, sélectionnez Teradata Vantage NOS.
 - Lorsque vous fournissez l'URL JDBC, indiquez l'URL de votre instance.
Vous pouvez également coder en dur certains paramètres de connexion séparés par des virgules dans votre URL JDBC. L'URL doit être conforme au format suivant : `jdbc:teradata://teradataHostname/ParameterName=ParameterValue,ParameterName=ParameterValue` .
 - Les paramètres d'URL pris en charge sont les suivants :
 - DATABASE – nom de la base de données sur l'hôte à laquelle accéder par défaut.
 - DBS_PORT – le port de base de données utilisé lors de l'exécution sur un port non standard.
 - Lorsque vous sélectionnez un type d'identifiant, sélectionnez AWS Secrets Manager, puis définissez AWS Secret sur *secretName*.
4. Dans les situations suivantes, vous pouvez avoir besoin d'une configuration supplémentaire :
 - Pour les instances Teradata hébergées AWS dans un Amazon VPC, vous devrez fournir les informations de connexion Amazon VPC à AWS Glue la connexion qui définit vos informations de sécurité Teradata. Lorsque vous créez ou mettez à jour votre connexion, définissez le VPC, le sous-réseau et les groupes de sécurité dans les options réseau.

Après avoir créé une connexion AWS Glue Teradata Vantage NOS, vous devez effectuer les étapes suivantes avant d'appeler votre méthode de connexion.

1. Accordez au rôle IAM associé à votre AWS Glue travail l'autorisation de lire *secretName*.
2. Dans la configuration de votre AWS Glue tâche, *connectionName* indiquez une connexion réseau supplémentaire sous Connexions.

Lecture à partir de tables Teradata

Prérequis :

- Une table Teradata à partir de laquelle vous souhaitez lire. Vous aurez besoin du nom de la table, *tableName*.
- L'environnement Teradata dispose d'un accès en écriture au chemin Amazon S3 spécifié par l'*staging_fs_url* option, *stagingFsUrl*.
- Le rôle IAM associé à la AWS Glue tâche dispose d'un accès en écriture à l'emplacement Amazon S3 spécifié par *staging_fs_url* option.
- Une connexion AWS Glue Teradata NOS configurée pour fournir des informations d'authentification. Suivez les étapes [Pour configurer une connexion AWS Glue Teradata NOS :](#) pour configurer vos informations d'authentification. Vous aurez besoin du nom de la AWS Glue connexion, *connectionName*.

Exemple :

```
teradata_read_table = glueContext.create_dynamic_frame.from_options(  
    connection_type= "teradatanos",  
    connection_options={  
        "connectionName": "connectionName",  
        "dbtable": "tableName",  
        "staging_fs_url": "stagingFsUrl"  
    }  
)
```

Vous pouvez également fournir une requête SQL SELECT pour filtrer les résultats renvoyés à votre DynamicFrame. Vous devrez configurer la requête. Si vous configurez à la fois DBTable et query, le connecteur ne parvient pas à lire les données. Par exemple :

```
teradata_read_query = glueContext.create_dynamic_frame.from_options(  

```

```

connection_type="teradatanos",
connection_options={
    "connectionName": "connectionName",
    "query": "query",
    "staging_fs_url": "stagingFsUrl"
}
)

```

En outre, vous pouvez utiliser l' DataFrame API Spark pour lire des tables Teradata. Par exemple :

```

options = {
    "url": "JDBC_URL",
    "dbtable": "tableName",
    "user": "teradataUsername", # or use "username" as key here
    "password": "teradataPassword",
    "staging_fs_url": "stagingFsUrl"
}
teradata_read_table = spark.read.format("teradatanos").option(**options).load()

```

Écrire dans les tables Teradata

Prérequis

- Une table Teradata dans laquelle vous souhaitez écrire : *tableName*.
- L'environnement Teradata dispose d'un accès en lecture à l'emplacement Amazon S3 spécifié par l'*staging_fs_url* option, *stagingFsUrl*.
- Le rôle IAM associé à la AWS Glue tâche dispose d'un accès en écriture à l'emplacement Amazon S3 spécifié par *staging_fs_url* option.
- Une connexion AWS Glue Teradata configurée pour fournir des informations d'authentification. Suivez les étapes décrites [Pour configurer une connexion AWS Glue Teradata NOS](#) : pour configurer vos informations d'authentification. Vous aurez besoin du nom de la AWS Glue connexion, *connectionName*.

Par exemple :

```

teradata_write = glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type= "teradatanos",
    connection_options={
        "connectionName": "connectionName",

```

```
    "dbtable": "tableName",  
    "staging_fs_url": "stagingFsUrl"  
  }  
)
```

Référence des options de connexion Teradata

Options de connexion et de fonctionnement :

- `connectionName` — Obligatoire. Utilisé pour la lecture/l'écriture. Nom d'une connexion AWS Glue Teradata configurée pour fournir des informations d'authentification et de mise en réseau à votre méthode de connexion.
- `staging_fs_url` — Obligatoire. Utilisé pour la lecture/l'écriture. Emplacement accessible en écriture dans Amazon S3, à utiliser pour les données déchargées lors de la lecture depuis Teradata, et pour les données Parquet à charger dans Redshift lors de l'écriture sur Teradata. Le compartiment S3 doit se trouver dans la même région que celle de vos AWS Glue tâches.
- `dbtable` — obligatoire pour l'écriture, obligatoire pour la lecture à moins qu'une query ne soit fournie. Utilisé pour la lecture/l'écriture. Le nom de la table avec laquelle votre méthode de connexion va interagir.
- `query` : utilisé pour la lecture. Une requête SELECT SQL définissant ce qui doit être récupéré lors de la lecture à partir de Teradata. Vous ne pouvez pas passer si `dbtable` l'option est fournie.
- `clean_staging_s3_dir`— Facultatif. Utilisé pour la lecture/l'écriture. Si c'est vrai, nettoyez les objets Amazon S3 intermédiaires après une lecture ou une écriture. La valeur par défaut est True.
- `pre_actions`— Facultatif. Utilisé pour écrire. Liste séparée par des points-virgules des commandes SQL exécutées avant le transfert des données entre Spark et Teradata Vantage.
- `post_actions`— Facultatif. Utilisé pour écrire. Liste de commandes SQL séparées par des points-virgules qui sont exécutées après le transfert de données entre Spark et Teradata Vantage.
- `truncate`— Facultatif. Utilisé pour écrire. Si c'est vrai, le connecteur tronque le tableau lors de l'écriture en mode de réécriture. Si la valeur est false, le connecteur supprime le tableau lors de l'écriture en mode de réécriture. La valeur par défaut est false.
- `create_table_script`— Facultatif. Utilisé pour écrire. Une instruction SQL pour créer une table lors de l'écriture sur Teradata Vantage. Utile lorsque vous souhaitez créer une table avec des métadonnées personnalisées (par exemple, CREATE MULTISSET ou SET table ou modifier l'index principal). Notez que le nom de table utilisé dans le script de création de table doit correspondre au nom de table spécifié dans `dbtable` l'option.

- `partition_size_in_mb`— Facultatif. Utilisé pour la lecture. Taille maximale d'une partition Spark en mégaoctets lors de la lecture d'objets Amazon S3 en cours de préparation. La valeur par défaut est 128.

Vous pouvez fournir des options avancées lors de la création d'un nœud Teradata. Ces options sont les mêmes que celles disponibles lors de la programmation AWS Glue de scripts Spark.

Consultez [the section called “Connexions Teradata Vantage”](#).

Options d'autorisation :

Vous trouverez ci-dessous les options utilisées pour fournir les informations d'identification du AWS compte que le connecteur utilise pour accéder au compartiment Amazon S3 intermédiaire. Vous pouvez choisir (1) de ne fournir aucune option d'autorisation et d'utiliser des informations d'identification temporaires générées à partir de votre rôle d' AWS Glue exécution ; ou (2) de fournir un objet d'autorisation `auth_object` que vous avez créé ; ou (3) de le fournir `aws_access_key_id` and `aws_secret_access_key` si vous utilisez des informations d'identification à long terme, ou de fournir `aws_access_key` `aws_secret_access_key`, et `aws_session_token` si vous utilisez des informations d'identification temporaires.

- `auth_object` : facultatif. Utilisé pour accéder au compartiment Amazon S3 intermédiaire. Chaîne d'objet d'autorisation créée dans une instance Teradata. S'il est fourni, le connecteur utilisera cet objet d'autorisation pour accéder au compartiment Amazon S3 intermédiaire. Si elles ne sont pas fournies, `aws_access_key_id` et `aws_secret_access_key` sont pas non plus, une information d'identification temporaire sera extraite du rôle AWS Glue d'exécution et utilisée par le connecteur. Le AWS compte associé à cet objet d'autorisation doit se trouver dans la même région que vos AWS Glue tâches et votre compartiment Amazon S3 intermédiaire ou être configuré avec la confiance entre comptes.
- `aws_access_key_id` : facultatif. Utilisé pour accéder au compartiment Amazon S3 intermédiaire. Fait partie d'un identifiant de sécurité du AWS compte. `auth_object` S'ils ne sont pas fournis et `aws_access_key_id` qu'ils sont fournis `aws_secret_access_key`, le connecteur les utilisera pour accéder au compartiment Amazon S3 intermédiaire. Le AWS compte associé à cette clé d'accès doit se trouver dans la même région que vos AWS Glue tâches et votre compartiment Amazon S3 intermédiaire ou être configuré avec la confiance entre comptes.
- `aws_secret_access_key` : facultatif. Utilisé pour accéder au compartiment Amazon S3 intermédiaire. Fait partie d'un identifiant de sécurité du AWS compte. `auth_object` S'ils ne sont pas fournis et `aws_secret_access_key` qu'ils sont fournis `aws_access_key_id`, le

connecteur les utilisera pour accéder au compartiment Amazon S3 intermédiaire. Le AWS compte associé à cette clé secrète doit se trouver dans la même région que vos AWS Glue tâches et votre compartiment Amazon S3 intermédiaire ou être configuré avec la confiance entre comptes.

- `aws_session_token` : facultatif. Utilisé pour accéder au compartiment Amazon S3 intermédiaire. Fait partie d'un identifiant de sécurité de AWS compte temporaire. Doit être fourni avec `aws_access_key_id` et `aws_secret_access_key`.

Fournir des options dans l'interface utilisateur AWS Glue Visual ETL

Vous pouvez fournir toutes les options ci-dessus dans l'interface utilisateur visuelle de votre tâche ETL. Pour l'option `ConnectionName`, vous devez la choisir dans la liste déroulante des connexions Teradata Vantage NOS. Pour toutes les autres options, vous devez les fournir via les propriétés personnalisées de Teradata Vantage NOS sous forme de paires clé-valeur.

Teradata Vantage NOS connection

Choose the AWS Glue connection for Teradata Vantage NOS, or [create a new connection](#).



▼ Custom Teradata Vantage NOS properties

Key	Value	
staging_fs_url	s3://your_staging_bucket/	<button>Remove</button>
dbtable	your_table	<button>Remove</button>
<button>Add row</button>		

Connexions Vertica

Vous pouvez utiliser AWS Glue for Spark pour lire et écrire dans des tables dans Vertica dans AWS Glue 4.0 et versions ultérieures. Vous pouvez définir ce qu'il faut lire dans Vertica à l'aide d'une requête SQL. Vous vous connectez à Vertica à l'aide du nom d'utilisateur et du mot de passe enregistrés AWS Secrets Manager via une connexion AWS Glue.

Pour de plus amples informations sur Vertica, consultez la [documentation Vertica](#).

Configuration de connexions Vertica

Pour vous connecter à Vertica depuis AWS Glue, vous devez créer et stocker vos informations d'identification Vertica dans un AWS Secrets Manager secret, puis associer ce secret à une connexion Vertica AWS Glue. Si votre instance Vertica se trouve dans un Amazon VPC, vous devrez

également fournir des options réseau à votre connexion AWS Glue Vertica. Vous aurez besoin d'un compartiment Amazon S3 ou d'un dossier à utiliser pour le stockage temporaire lors de la lecture et de l'écriture dans la base de données.

Pour vous connecter à Vertica depuis AWS Glue, vous aurez besoin de certaines conditions préalables :

- Un compartiment ou un dossier Amazon S3 à utiliser pour le stockage temporaire lors de la lecture et de l'écriture dans la base de données, désigné par *tempS3Path*.

 Note

Lorsque vous utilisez Vertica dans les aperçus des données des tâches AWS Glue, il est possible que les fichiers temporaires ne soient pas automatiquement supprimés.

tempS3Path Pour garantir la suppression des fichiers temporaires, mettez directement fin à la session de prévisualisation des données en choisissant Mettre fin à la session dans le volet Prévisualisation des données.

Si vous ne pouvez pas garantir la fin directe de la session de prévisualisation des données, pensez à configurer le cycle de vie d'Amazon S3 pour supprimer les anciennes données.

Nous recommandons de supprimer les données de plus de 49 heures, sur la base de la durée d'exécution maximale des tâches plus une marge. Pour de plus amples informations sur la configuration du cycle de vie Amazon S3, consultez [Gestion du cycle de vie de votre stockage](#) dans la documentation Amazon S3.

- Une politique IAM avec les autorisations appropriées pour votre chemin Amazon S3 que vous pouvez associer à votre rôle de travail AWS Glue.
- Si votre instance Vertica se trouve dans un Amazon VPC, configurez Amazon VPC pour permettre à votre tâche AWS Glue de communiquer avec l'instance Vertica sans que le trafic ne transite par l'Internet public.

Dans Amazon VPC, identifiez ou créez un VPC, un sous-réseau et un groupe de sécurité que AWS Glue utilisera lors de l'exécution de la tâche. En outre, vous devez vous assurer qu'Amazon VPC est configuré pour autoriser le trafic réseau entre votre instance Vertica et cet emplacement. Votre tâche devra établir une connexion TCP avec votre port client Vertica (par défaut 5433). Selon la configuration de votre réseau, cela peut nécessiter des modifications des règles du groupe de sécurité, du réseau ACLs, des passerelles NAT et des connexions d'appairage.

Vous pouvez ensuite configurer AWS Glue pour l'utiliser avec Vertica.

Pour configurer une connexion à Vertica :

1. Dans AWS Secrets Manager, créez un secret à l'aide de vos informations d'identification Vertica, *verticaUsername* et *verticaPassword*. Pour créer un secret dans Secrets Manager, suivez le didacticiel disponible dans la [section Créer un AWS Secrets Manager secret](#) dans la AWS Secrets Manager documentation. Après avoir créé le secret, conservez le nom du secret *secretName* pour l'étape suivante.
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé user contenant la valeur. *verticaUsername*
 - Lorsque vous sélectionnez des paires clé/valeur, créez une paire pour la clé password contenant la valeur. *verticaPassword*
2. Dans la console AWS Glue, créez une connexion en suivant les étapes décrites dans [the section called "Ajouter une AWS Glue connexion"](#). Après avoir créé la connexion, conservez le nom de la connexion pour l'étape suivante. *connectionName*
 - Lorsque vous sélectionnez un type de connexion, sélectionnez Vertica.
 - Lorsque vous sélectionnez l'hôte Vertica, indiquez le nom d'hôte de votre installation Vertica.
 - Lorsque vous sélectionnez le port Vertica, le port via lequel votre installation Vertica est disponible.
 - Lorsque vous sélectionnez un AWS secret, indiquez-le *secretName*.
3. Dans les situations suivantes, vous pouvez avoir besoin d'une configuration supplémentaire :
 - Pour les instances Vertica hébergées AWS dans un Amazon VPC
 - Fournissez les informations de connexion Amazon VPC à la connexion AWS Glue qui définit vos informations de sécurité Vertica. Lorsque vous créez ou mettez à jour votre connexion, définissez le VPC, le sous-réseau et les groupes de sécurité dans les options réseau.

Après avoir créé une connexion AWS Glue Vertica, vous devez effectuer les étapes suivantes avant d'appeler votre méthode de connexion.

- Accordez au rôle IAM associé à votre tâche AWS Glue des autorisations à *tempS3Path*.
- Accordez au rôle IAM associé à votre tâche AWS Glue l'autorisation de lire *secretName*.
- Dans la configuration de votre tâche AWS Glue *connectionName*, fournissez une connexion réseau supplémentaire.

Lecture à partir de Vertica

Prérequis :

- Une table Vertica à partir de laquelle vous souhaitez lire. Vous aurez besoin du nom de la base de données Vertica *dbName* et du nom de la table. *tableName*
- Une connexion AWS Glue Vertica configurée pour fournir des informations d'authentification. Suivez les étapes de la procédure précédente Pour configurer une connexion à Vertica afin de configurer vos informations d'authentification. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.
- Un compartiment ou un dossier Amazon S3 à utiliser pour le stockage temporaire, mentionné précédemment. Vous aurez besoin du nom, *tempS3Path*. Vous devrez vous connecter à cet emplacement à l'aide du protocole s3a.

Par exemple :

```
dynamicFrame = glueContext.create_dynamic_frame.from_options(  
    connection_type="vertica",  
    connection_options={  
        "connectionName": "connectionName",  
        "staging_fs_url": "s3a://tempS3Path",  
        "db": "dbName",  
        "table": "tableName",  
    }  
)
```

Vous pouvez également fournir une requête SQL SELECT pour filtrer les résultats qui vous sont renvoyés DynamicFrame ou pour accéder à un ensemble de données à partir de plusieurs tables.

Par exemple :

```
dynamicFrame = glueContext.create_dynamic_frame.from_options(  
    connection_type="vertica",  
    connection_options={  
        "connectionName": "connectionName",  
        "staging_fs_url": "s3a://tempS3Path",  
        "db": "dbName",  
        "query": "select * FROM tableName",  
    },  
)
```

Écrire dans les tables Vertica

Cet exemple écrit les informations d'un fichier existant `DynamicFrame` *dynamicFrame* dans Vertica. Si le tableau contient déjà des informations, AWS Glue ajoutera les données de votre `DynamicFrame`.

Prérequis :

- Nom de table actuel ou souhaité *tableName*, dans lequel vous souhaitez écrire. Vous aurez également besoin du nom de base de données Vertica correspondant, *dbName*.
- Une connexion AWS Glue Vertica configurée pour fournir des informations d'authentification. Suivez les étapes de la procédure précédente Pour configurer une connexion à Vertica afin de configurer vos informations d'authentification. Vous aurez besoin du nom de la connexion AWS Glue, *connectionName*.
- Un compartiment ou un dossier Amazon S3 à utiliser pour le stockage temporaire, mentionné précédemment. Vous aurez besoin du nom, *tempS3Path*. Vous devrez vous connecter à cet emplacement à l'aide du protocole s3a.

Par exemple :

```
glueContext.write_dynamic_frame.from_options(  
    frame=dynamicFrame,  
    connection_type="vertica",  
    connection_options={  
        "connectionName": "connectionName",  
        "staging_fs_url": "s3a://tempS3Path",  
        "db": "dbName",  
        "table": "tableName",  
    }  
)
```

Référence des options de connexion Vertica

- `connectionName` — Obligatoire. Utilisé pour la lecture/l'écriture. Le nom d'une connexion AWS Glue Vertica configurée pour fournir des informations d'authentification et de réseau à votre méthode de connexion.
- `db` — Obligatoire. Utilisé pour la lecture/l'écriture. Le nom d'une base de données dans Vertica avec laquelle votre méthode de connexion va interagir.

- `dbSchema` — obligatoire si nécessaire pour identifier votre table. Utilisé pour la lecture/l'écriture. Par défaut: `public`. Le nom d'un schéma avec lequel votre méthode de connexion va interagir.
- `table` — obligatoire pour l'écriture, obligatoire pour la lecture à moins qu'une query ne soit fournie. Utilisé pour la lecture/l'écriture. Le nom de la table avec laquelle votre méthode de connexion va interagir.
- `query` : utilisé pour la lecture. Une requête SELECT SQL définissant ce qui doit être récupéré lors de la lecture à partir de Teradata.
- `staging_fs_url` — Obligatoire. Utilisé pour la lecture/l'écriture. Valeurs valides : s3a URLs. L'URL d'un compartiment ou d'un dossier Amazon S3 à utiliser pour le stockage temporaire.

DataFrame options pour l'ETL dans AWS Glue 5.0 pour Spark

A DataFrame est un ensemble de données organisé en colonnes nommées semblables à une table et prenant en charge les opérations de style fonctionnel (`map/reduce/filter/etc.`) et les opérations SQL (sélection, projet, agrégation).

Pour créer un DataFrame pour une source de données prise en charge par Glue, les éléments suivants sont requis :

- connecteur de source de données `ClassName`
- connexion à une source de données `Options`

De même, pour écrire un dans DataFrame un récepteur de données supporté par Glue, il en va de même :

- connecteur de récepteur de données `ClassName`
- connexion au récepteur de données `Options`

Notez que les fonctionnalités de AWS Glue telles que les signets de tâches et les `DynamicFrame` options telles que celles-ci ne `connectionName` sont pas prises en charge dans DataFrame. Pour plus de détails sur les opérations prises en charge DataFrame et pour en savoir plus, consultez la documentation de Spark pour [DataFrame](#).

Spécification du connecteur `ClassName`

Pour spécifier une source/un récepteur `ClassName` de données, utilisez l' `formatoption` permettant de fournir le connecteur correspondant `ClassName` qui définit la source/le récepteur de données.

Connecteurs JDBC

Pour les connecteurs JDBC, spécifiez `jdbc` la valeur de `'format.option'` et fournissez le pilote `ClassName JDBC` dans l'option `driver`

```
df = spark.read.format("jdbc").option("driver", "<DATA SOURCE JDBC DRIVER  
CLASSNAME>")...  
  
df.write.format("jdbc").option("driver", "<DATA SINK JDBC DRIVER CLASSNAME>")...
```

Le tableau suivant répertorie le pilote JDBC de la source `ClassName` de données prise en charge dans AWS Glue for DataFrames

Source de données	Chauffeur ClassName
PostgreSQL	org.postgresql.Driver
Oracle	oracle.jdbc.driver.OracleDriver
SQLServer	com.microsoft.sqlserver.jdbc.SQLServerDriver
MySQL	com.mysql.jdbc.Driver
SAPHana	com.sap.db.jdbc.Driver
Teradata	com.teradata.jdbc.TeraDriver

Connecteurs Spark

Pour les connecteurs Spark, spécifiez le `ClassName` connecteur comme valeur de `'format.option'`.

```
df = spark.read.format("<DATA SOURCE CONNECTOR CLASSNAME>")...  
  
df.write.format("<DATA SINK CONNECTOR CLASSNAME>")...
```

Le tableau suivant répertorie le connecteur Spark `ClassName` de la source de données prise en charge dans AWS Glue for DataFrames.

Source de données	ClassName
MongoDB/DocumentDB	glue.spark.mongodb
Redshift	io.github.spark_redshift_community.spark.redshift
AzureCosmos	cosmos.oltp
AzureSQL	com.microsoft.sqlserver.jdbc.spark
BigQuery	com.google.cloud.spark.bigquery
OpenSearch	org.opensearch.spark.sql
Snowflake	net.snowflake.spark.snowflake
Vertica	com.vertica.spark.datasource.VerticaSource

Spécification des options de connexion

Pour spécifier `Options` la connexion à une source/un récepteur de données, utilisez le `.option(<KEY>, <VALUE>)` pour fournir des options individuelles ou `.options(<MAP>)` pour fournir plusieurs options sous forme de carte clé-valeur.

Chaque source/récepteur de données prend en charge son propre ensemble de connexions. `Options` Pour plus de détails sur les connecteurs Spark disponibles `Options`, reportez-vous à la documentation publique du connecteur Spark spécifique à la source/au récepteur de données répertorié dans le tableau suivant.

- [JDBC](#)
- [MongoDB/DocumentDB](#)
- [Redshift](#)
- [AzureCosmos](#)
- [AzureSQL](#)
- [BigQuery](#)
- [OpenSearch](#)

- [Snowflake](#)
- [Vertica](#)

Exemples

Les exemples suivants sont extraits de PostgreSQL et écrivent dans : Snowflake

Python

Exemple :

```
from awsglue.context import GlueContext
from pyspark.sql import SparkSession

spark = SparkSession.builder.getOrCreate()

dataSourceClassName = "jdbc"
dataSourceOptions = {
    "driver": "org.postgresql.Driver",
    "url": "<url>",
    "user": "<user>",
    "password": "<password>",
    "dbtable": "<dbtable>",
}

dataframe = spark.read.format(className).options(**options).load()

dataSinkClassName = "net.snowflake.spark.snowflake"
dataSinkOptions = {
    "sfUrl": "<url>",
    "sfUsername": "<username>",
    "sfPassword": "<password>",
    "sfDatabase" -> "<database>",
    "sfSchema" -> "<schema>",
    "sfWarehouse" -> "<warehouse>"
}

dataframe.write.format(dataSinkClassName).options(**dataSinkOptions).save()
```

Scala

Exemple :

```
import org.apache.spark.sql.SparkSession

val spark = SparkSession.builder().getOrCreate()

val dataSourceClassName = "jdbc"
val dataSourceOptions = Map(
  "driver" -> "org.postgresql.Driver",
  "url" -> "<url>",
  "user" -> "<user>",
  "password" -> "<password>",
  "dbtable" -> "<dbtable>"
)

val dataframe =
  spark.read.format(dataSourceClassName).options(dataSourceOptions).load()

val dataSinkClassName = "net.snowflake.spark.snowflake"
val dataSinkOptions = Map(
  "sfUrl" -> "<url>",
  "sfUsername" -> "<username>",
  "sfPassword" -> "<password>",
  "sfDatabase" -> "<database>",
  "sfSchema" -> "<schema>",
  "sfWarehouse" -> "<warehouse>"
)

dataframe.write.format(dataSinkClassName).options(dataSinkOptions).save()
```

Valeurs personnalisées et AWS Marketplace ConnectionType

Tel est le cas des éléments suivants :

- "connectionType": "marketplace.athena" : désigne une connexion à un magasin de données Amazon Athena. La connexion utilise un connecteur provenant de AWS Marketplace.
- "connectionType": "marketplace.spark" : désigne une connexion à un magasin de données Apache Spark. La connexion utilise un connecteur provenant de AWS Marketplace.
- "connectionType": "marketplace.jdbc" : désigne une connexion à un magasin de données JDBC. La connexion utilise un connecteur provenant de AWS Marketplace.
- "connectionType": "custom.athena" : désigne une connexion à un magasin de données Amazon Athena. La connexion utilise un connecteur personnalisé que vous téléchargez vers AWS Glue Studio.

- `"connectionType": "custom.spark"` : désigne une connexion à un magasin de données Apache Spark. La connexion utilise un connecteur personnalisé que vous téléchargez vers AWS Glue Studio.
- `"connectionType": "custom.jdbc"` : désigne une connexion à un magasin de données JDBC. La connexion utilise un connecteur personnalisé que vous téléchargez vers AWS Glue Studio.

Options de connexion pour le type `custom.jdbc` ou `marketplace.jdbc`

- `className` — chaîne, obligatoire, nom de la classe du pilote.
- `connectionName` — chaîne, obligatoire, nom de la connexion associée au connecteur.
- `url` — chaîne, obligatoire, URL JDBC avec des espaces réservés (`${}`) qui sont utilisés pour créer la connexion à la source de données. L'espace réservé `${secretKey}` est remplacé par le secret du même nom dans AWS Secrets Manager. Reportez-vous à la documentation du magasin de données pour plus d'informations sur la construction de l'URL.
- `secretId` ou `user/password` — chaîne, obligatoire, utilisée pour récupérer les informations d'identification de l'URL.
- `dbTable` ou `query` — chaîne, obligatoire, la table ou la requête SQL à partir de laquelle obtenir les données. Vous pouvez préciser `dbTable` ou `query`, mais pas les deux.
- `partitionColumn` — chaîne, facultatif, nom d'une colonne entière utilisée pour le partitionnement. Cette option fonctionne uniquement lorsqu'elle est incluse dans `lowerBound`, `upperBound` et `numPartitions`. Cette option fonctionne de la même manière que dans le lecteur JDBC SQL Spark. Pour plus d'informations, consultez la section [JDBC vers d'autres bases de données](#) dans le guide Apache Spark SQL DataFrames et Datasets.

Les valeurs `lowerBound` et `upperBound` sont utilisées pour décider de la progression de la partition, pas pour filtrer les lignes de la table. Toutes les lignes de la table sont partitionnées et renvoyées.

Note

Lorsque vous utilisez une requête au lieu d'un nom de table, vous devez valider que la requête fonctionne avec la condition de partitionnement spécifiée. Par exemple :

- Si le format de votre requête est `"SELECT col1 FROM table1"`, testez la requête en ajoutant une clause `WHERE` à la fin de la requête qui utilise la colonne de partition.

- Si le format de votre requête est `SELECT col1 FROM table1 WHERE col2=val`", testez la requête en étendant la clause `WHERE` avec `AND` et une expression qui utilise la colonne de partition.

- `lowerBound` — entier, facultatif, valeur minimale de `partitionColumn` qui est utilisée pour décider de la progression de la partition.
- `upperBound` — entier, facultatif, valeur maximale de `partitionColumn` qui est utilisée pour décider de la progression de la partition.
- `numPartitions` — entier, facultatif, nombre de partitions. Cette valeur, ainsi que `lowerBound` (inclusive) et `upperBound` (exclusive) forment les progressions de partition pour les expressions de clause `WHERE` générées qui sont utilisées pour diviser le fichier `partitionColumn`.

 Important

Soyez prudent avec le nombre de partitions, car avoir un trop grand nombre de partitions peut causer des problèmes sur vos systèmes de bases de données externes.

- `filterPredicate` — chaîne, facultative, clause de condition supplémentaire pour filtrer les données à partir de la source. Par exemple :

```
BillingCity='Mountain View'
```

Lorsque vous utilisez une requête au lieu d'un nom de table, vous devez vérifier que la requête fonctionne avec le `filterPredicate` spécifié. Par exemple :

- Si le format de votre requête est `"SELECT col1 FROM table1"`, testez la requête en ajoutant une clause `WHERE` à la fin de la requête qui utilise le prédicat de filtre.
- Si le format de votre requête est `"SELECT col1 FROM table1 WHERE col2=val"`, testez la requête en étendant la clause `WHERE` avec `AND` et une expression qui utilise le prédicat de filtre.
- `dataTypeMapping` — dictionnaire, facultatif, mappage de type de données personnalisé qui crée un mappage d'un type de données JDBC à un type de données Glue. Par exemple, l'option `"dataTypeMapping":{"FLOAT":"STRING"}` mappe les champs de données de type JDBC `FLOAT` dans le `String` type Java en appelant la `ResultSet.getString()` méthode du pilote, et l'utilise pour créer AWS Glue records. L'objet est `ResultSet` implémenté par chaque pilote, donc le comportement est spécifique au pilote que vous utilisez. Reportez-vous à la documentation de votre pilote JDBC pour comprendre comment le pilote effectue les conversions.
- Le AWS Glue les types de données actuellement pris en charge sont les suivants :

- DATE
- CHAÎNE
- TIMESTAMP
- INT
- FLOAT
- LONG
- BIGDECIMAL
- BYTE
- SHORT
- DOUBLE

Les types de données JDBC pris en charge sont [Java8 java.sql.types](#).

Les mappages de types de données par défaut (de JDBC à AWS Glue) sont :

- DATE -> DATE
- VARCHAR -> STRING
- CHAR -> STRING
- LONGNVARCHAR -> STRING
- TIMESTAMP -> TIMESTAMP
- INTEGER -> INT
- FLOAT -> FLOAT
- REAL -> FLOAT
- BIT -> BOOLEAN
- BOOLEAN -> BOOLEAN
- BIGINT -> LONG
- DECIMAL -> BIGDECIMAL
- NUMERIC -> BIGDECIMAL
- TINYINT -> SHORT
- SMALLINT -> SHORT
- DOUBLE -> DOUBLE

Si vous utilisez un mappage de type de données personnalisé avec l'option `dataTypeMapping`, vous pouvez remplacer un mappage de type de données par défaut. Seuls les types de données JDBC répertoriés dans l'option `dataTypeMapping` sont affectés ; le mappage par défaut est utilisé pour tous les autres types de données JDBC. Vous pouvez ajouter des mappages pour des types de données JDBC supplémentaires si nécessaire. Si un type de données JDBC n'est inclus ni dans le mappage par défaut ni dans le mappage personnalisé, le type de données est converti en AWS Glue `STRING` type de données par défaut.

L'exemple de code Python suivant montre comment lire à partir de bases de données JDBC avec des pilotes AWS Marketplace JDBC. Il montre la lecture à partir d'une base de données et l'écriture dans un emplacement S3.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

## @params: [JOB_NAME]
args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args['JOB_NAME'], args)
## @type: DataSource
## @args: [connection_type = "marketplace.jdbc", connection_options =
    {"dataTypeMapping":{"INTEGER":"STRING"},"upperBound":"200","query":"select id,
        name, department from department where id < 200","numPartitions":"4",
        "partitionColumn":"id","lowerBound":"0","connectionName":"test-connection-
jdbc"},
    transformation_ctx = "DataSource0"]
## @return: DataSource0
## @inputs: []
DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type =
    "marketplace.jdbc", connection_options = {"dataTypeMapping":{"INTEGER":"STRING"},
    "upperBound":"200","query":"select id, name, department from department where
    id < 200","numPartitions":"4","partitionColumn":"id","lowerBound":"0",
```

```

        "connectionName":"test-connection-jdbc"}, transformation_ctx = "DataSource0")
    ## @type: ApplyMapping
    ## @args: [mappings = [("department", "string", "department", "string"), ("name",
"string",
        "name", "string"), ("id", "int", "id", "int")], transformation_ctx =
"Transform0"]
    ## @return: Transform0
    ## @inputs: [frame = DataSource0]
    Transform0 = ApplyMapping.apply(frame = DataSource0, mappings = [("department",
"string",
        "department", "string"), ("name", "string", "name", "string"), ("id", "int",
"id", "int")],
        transformation_ctx = "Transform0")
    ## @type: DataSink
    ## @args: [connection_type = "s3", format = "json", connection_options = {"path":
"s3://<S3 path>/", "partitionKeys": []}, transformation_ctx = "DataSink0"]
    ## @return: DataSink0
    ## @inputs: [frame = Transform0]
    DataSink0 = glueContext.write_dynamic_frame.from_options(frame = Transform0,
        connection_type = "s3", format = "json", connection_options = {"path":
"s3://<S3 path>/", "partitionKeys": []}, transformation_ctx = "DataSink0")
    job.commit()

```

Options de connexion pour le type custom.athena ou marketplace.athena

- **className** — chaîne, obligatoire, nom de la classe du pilote. Lorsque vous utilisez le CloudWatch connecteur Athena, cette valeur de paramètre est le préfixe de la classe Name (par exemple,). "com.amazonaws.athena.connectors" Le CloudWatch connecteur Athena est composé de deux classes : un gestionnaire de métadonnées et un gestionnaire d'enregistrements. Si vous fournissez le préfixe commun ici, l'API charge les classes correctes en fonction de ce préfixe.
- **tableName**— Chaîne, obligatoire, nom du flux de CloudWatch journal à lire. Cet extrait de code utilise le nom de vue spécial `all_log_streams`, ce qui signifie que la trame de données dynamique renvoyée contiendra les données de tous les flux de journaux du groupe de journaux.
- **schemaName**— Chaîne, obligatoire, nom du groupe de CloudWatch journaux à partir duquel la lecture doit être effectuée. Par exemple, `/aws-glue/jobs/output`.
- **connectionName** — chaîne, obligatoire, nom de la connexion associée au connecteur.

Pour des options supplémentaires pour ce connecteur, consultez le [fichier README du CloudWatch connecteur Amazon Athena](#) sur GitHub

L'exemple de code Python suivant montre comment lire à partir d'un magasin de données Athena à l'aide d'un connecteur AWS Marketplace . Il montre la lecture à partir d'Athena et l'écriture dans un emplacement S3.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

## @params: [JOB_NAME]
args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args['JOB_NAME'], args)
## @type: DataSource
## @args: [connection_type = "marketplace.athena", connection_options =
    {"tableName": "all_log_streams", "schemaName": "/aws-glue/jobs/output",
     "connectionName": "test-connection-athena"}, transformation_ctx = "DataSource0"]
## @return: DataSource0
## @inputs: []
DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type =
    "marketplace.athena", connection_options = {"tableName": "all_log_streams",
    "schemaName": "/aws-glue/jobs/output", "connectionName":
    "test-connection-athena"}, transformation_ctx = "DataSource0")
## @type: ApplyMapping
## @args: [mappings = [("department", "string", "department", "string"), ("name",
"string",
    "name", "string"), ("id", "int", "id", "int")], transformation_ctx =
"Transform0"]
## @return: Transform0
## @inputs: [frame = DataSource0]
Transform0 = ApplyMapping.apply(frame = DataSource0, mappings = [("department",
"string",
    "department", "string"), ("name", "string", "name", "string"), ("id", "int",
"id", "int")],
    transformation_ctx = "Transform0")
## @type: DataSink
## @args: [connection_type = "s3", format = "json", connection_options = {"path":
```

```

"s3://<S3 path>/", "partitionKeys": []}, transformation_ctx = "DataSink0"]
## @return: DataSink0
## @inputs: [frame = Transform0]
DataSink0 = glueContext.write_dynamic_frame.from_options(frame = Transform0,
    connection_type = "s3", format = "json", connection_options = {"path":
    "s3://<S3 path>/", "partitionKeys": []}, transformation_ctx = "DataSink0")
job.commit()

```

Options de connexion pour le type custom.spark ou marketplace.spark

- `className` — chaîne, obligatoire, nom de la classe du connecteur.
- `secretId` — chaîne, facultative, utilisée pour récupérer les informations d'identification pour la connexion du connecteur.
- `connectionName` — chaîne, obligatoire, nom de la connexion associée au connecteur.
- D'autres options dépendent du magasin de données. Par exemple, les options OpenSearch de configuration commencent par le préfixe `sf`, comme décrit dans la documentation d'[Elasticsearch pour Apache Hadoop](#). Les connexions Spark à Snowflake utilisent des options telles que `sfUser` et `sfPassword`, comme décrit dans [Using the Spark Connector](#) dans le guide [Connecting to Snowflake](#).

L'exemple de code Python suivant montre comment lire depuis un magasin de OpenSearch données à l'aide d'une `marketplace.spark` connexion.

```

import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

## @params: [JOB_NAME]
args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args['JOB_NAME'], args)
## @type: DataSource

```

```

## @args: [connection_type = "marketplace.spark", connection_options =
{"path":"test",
  "es.nodes.wan.only":"true","es.nodes":"https://<AWS endpoint>",
  "connectionName":"test-spark-es","es.port":"443"}, transformation_ctx =
"DataSource0"]
## @return: DataSource0
## @inputs: []
DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type =
  "marketplace.spark", connection_options = {"path":"test","es.nodes.wan.only":
  "true","es.nodes":"https://<AWS endpoint>","connectionName":
  "test-spark-es","es.port":"443"}, transformation_ctx = "DataSource0")
## @type: DataSink
## @args: [connection_type = "s3", format = "json", connection_options = {"path":
  "s3://<S3 path>/", "partitionKeys": []}, transformation_ctx = "DataSink0"]
## @return: DataSink0
## @inputs: [frame = DataSource0]
DataSink0 = glueContext.write_dynamic_frame.from_options(frame = DataSource0,
  connection_type = "s3", format = "json", connection_options = {"path":
  "s3://<S3 path>/", "partitionKeys": []}, transformation_ctx = "DataSink0")
job.commit()

```

Options générales

Les options de cette section sont fournies en tant que `connection_options`, mais ne s'appliquent pas à un connecteur en particulier.

Les paramètres suivants sont généralement utilisés lors de la configuration de signets. Ils peuvent s'appliquer aux flux de travail Amazon S3 ou JDBC. Pour de plus amples informations, veuillez consulter [the section called “Utilisation des marque-pages de tâche”](#).

- `jobBookmarkKeys` : un tableau des noms des colonnes.
- `jobBookmarkKeysSortOrder` : chaîne définissant comment comparer les valeurs en fonction de l'ordre de tri. Valeurs valides : "asc", "desc".
- `useS3ListImplementation` : utilisé pour gérer les performances de la mémoire lors de la liste du contenu du compartiment Amazon S3. Pour plus d'informations, consultez [Optimiser la gestion de la mémoire dans AWS Glue](#).

Options de format de données pour les entrées et les sorties dans AWS Glue pour Spark

Ces pages fournissent des informations sur la prise en charge des fonctionnalités et les paramètres de configuration pour les formats de données pris en charge par AWS Glue pour Spark. Reportez-vous à la section suivante pour une description de l'utilisation et de l'applicabilité de ces informations.

Support des fonctionnalités dans tous les formats de données dans AWS Glue

Chaque format de données peut prendre en charge différentes fonctionnalités AWS de Glue. Les fonctionnalités communes suivantes peuvent être prises en charge ou non en fonction de votre type de format. Reportez-vous à la documentation de votre format de données pour comprendre comment tirer parti de nos caractéristiques pour répondre à vos besoins.

Lecture	AWS Glue peut reconnaître et interpréter ce format de données sans ressources supplémentaires, telles que des connecteurs.
---------	--

Écrire	AWS Glue peut écrire des données dans ce format sans ressources supplémentaires. Vous pouvez inclure des bibliothèques tierces dans votre travail et utiliser les fonctions standard d'Apache Spark pour écrire des données, comme vous le feriez dans d'autres environnements Spark. Pour plus d'informations sur ces bibliothèques, consultez the section called “Bibliothèques Python” .
--------	---

Lecture en streaming	AWS Glue peut reconnaître et interpréter ce format de données à partir d'un flux de messages Apache Kafka, Amazon Managed Streaming for Apache Kafka ou Amazon Kinesis. Nous nous attendons à ce que les flux présentent les données dans un format cohérent, afin qu'elles soient lues comme DataFrames .
----------------------	--

Grouper t des petits fichiers	AWS Glue peut regrouper des fichiers pour créer un travail par lots envoyé à chaque nœud lors de transformations avec AWS Glue. Cela peut améliorer considérablement les performances pour les charges de travail impliquant de grandes quantités de petits fichiers. Pour de plus amples informations, veuillez consulter the section called “Groupement des fichiers d'entrée” .
--	--

Signets de tâche	AWS Glue peut suivre la progression des transformations effectuant le même travail sur le même jeu de données d'une exécution à l'autre à l'aide de signets de tâches. Cela peut améliorer les performances des charges de travail impliquant des jeux de données pour lesquels le travail doit uniquement être effectué sur les nouvelles données depuis la dernière exécution de la tâche. Pour de plus amples informations, veuillez consulter the section called “Suivi des données traitées à l'aide de signets de tâche” .
------------------------	--

Paramètres utilisés pour interagir avec les formats de données dans AWS Glue

Certains types de connexion AWS Glue prennent en charge plusieurs format types, ce qui vous oblige à spécifier des informations sur le format de vos données avec un `format_options` objet lorsque vous utilisez des méthodes telles que `GlueContext.write_dynamic_frame.from_options`.

- **s3**— Pour plus d'informations, consultez Types de connexion et options pour l'ETL dans AWS Glue : [Paramètres de connexion S3](#). Vous pouvez également afficher la documentation des méthodes facilitant ce type de connexion : [the section called “create_dynamic_frame_from_options”](#) et [the section called “write_dynamic_frame_from_options”](#) en Python et dans les méthodes Scala correspondantes [the section called “getSourceWithFormatter”](#) et [the section called “getSinkWithFormatter”](#).

- `kinesis`— Pour plus d'informations, consultez Types de connexion et options pour l'ETL dans AWS Glue : [Paramètres de connexion Kinesis](#). Vous pouvez également afficher la documentation de la méthode facilitant ce type de connexion : [the section called “create_data_frame_from_options”](#) et la méthode Scala correspondante [the section called “createDataFrameFromOptions”](#).
- `kafka`— Pour plus d'informations, consultez Types de connexion et options pour l'ETL dans AWS Glue : [Paramètres de connexion de Kafka](#). Vous pouvez également afficher la documentation de la méthode facilitant ce type de connexion : [the section called “create_data_frame_from_options”](#) et la méthode Scala correspondante [the section called “createDataFrameFromOptions”](#).

Certains types de connexion ne nécessitent pas `format_options`. Par exemple, dans le cadre d'une utilisation normale, une connexion JDBC à une base de données relationnelle récupère les données dans un format de données tabulaire cohérent. Par conséquent, la lecture à partir d'une connexion JDBC ne nécessiterait pas `format_options`.

Certaines méthodes pour lire et écrire des données dans de la colle ne nécessitent pas `format_options`. Par exemple, en utilisant `GlueContext.create_dynamic_frame.from_catalog` les crawlers AWS Glue. Les robots d'exploration déterminent la forme de vos données. Lorsque vous utilisez des robots d'exploration, un classificateur AWS Glue examinera vos données afin de prendre des décisions éclairées quant à la manière de représenter le format de vos données. Il stockera ensuite une représentation de vos données dans le catalogue de données AWS Glue, qui peut être utilisé dans un script AWS Glue ETL pour récupérer vos données avec la `GlueContext.create_dynamic_frame.from_catalog` méthode. Les robots d'exploration éliminent la nécessité de spécifier manuellement des informations sur le format de vos données.

Pour les tâches qui accèdent à des tables AWS Lake Formation gouvernées, AWS Glue prend en charge la lecture et l'écriture de tous les formats pris en charge par les tables régies par Lake Formation. Pour consulter la liste actuelle des formats pris en charge pour les tables AWS Lake Formation gouvernées, consultez la section [Remarques et restrictions relatives aux tables gouvernées](#) dans le guide du AWS Lake Formation développeur.

Note

Pour écrire Apache Parquet, AWS Glue L'ETL prend uniquement en charge l'écriture dans une table gouvernée en spécifiant une option pour un type de rédacteur de parquet personnalisé optimisé pour les cadres dynamiques. Lorsque vous écrivez sur une table régie

avec le format parquet, vous devez ajouter la clé `useGlueParquetWriter` avec une valeur de `true` dans les paramètres de la table.

Rubriques

- [Utilisation du format CSV dans AWS Glue](#)
- [Utilisation du format Parquet dans AWS Glue](#)
- [Utilisation du format XML dans AWS Glue](#)
- [Utilisation du format Avro dans Glue AWS](#)
- [Utilisation du format GrokLog dans Glue AWS](#)
- [Utilisation du format Ion dans AWS Glue](#)
- [Utilisation du format JSON dans AWS Glue](#)
- [Utilisation du format ORC dans Glue AWS](#)
- [Utilisation de frameworks de lacs de données avec des tâches AWS Glue ETL](#)
- [Référence de configuration partagée](#)

Utilisation du format CSV dans AWS Glue

AWS Glue récupère les données des sources et écrit les données sur des cibles stockées et transportées dans différents formats de données. Si vos données sont stockées ou transportées au format CSV, ce document présente les fonctionnalités disponibles pour utiliser vos données dans AWS Glue.

AWS Glue prend en charge l'utilisation du format CSV (valeurs séparées par des virgules). Il s'agit d'un format de données minimal basé sur des lignes. CSVs ne sont souvent pas strictement conformes à une norme, mais vous pouvez vous référer aux [RFC 4180](#) et [RFC 7111](#) pour plus d'informations.

Vous pouvez utiliser AWS Glue pour lire CSVs depuis Amazon S3 et depuis des sources de streaming, ainsi que CSVs pour écrire sur Amazon S3. Vous pouvez lire et écrire des archives bzip et gzip contenant des fichiers CSV provenant de S3. Vous configurez le comportement de compression sur [Paramètres de connexion S3](#) plutôt que dans la configuration décrite sur cette page.

Le tableau suivant indique les fonctionnalités courantes de AWS Glue compatibles avec l'option de format CSV.

Lecture	Écrire	Lecture en streaming	Groupeement des petits fichiers	Signets de tâche
Pris en charge	Pris en charge	Pris en charge	Pris en charge	Pris en charge

Exemple : lecture de fichiers ou de dossiers CSV depuis S3

Prérequis : vous aurez besoin des chemins S3 (`s3path`) vers des fichiers ou dossiers CSV que vous souhaitez lire.

Configuration : dans vos options de fonction, spécifiez `format="csv"`. Dans vos `connection_options`, utilisez la clé `paths` pour spécifier `s3path`. Vous pouvez configurer la manière dont le lecteur interagit avec S3 dans `connection_options`. Pour plus de détails, voir Types de connexion et options pour l'ETL dans AWS Glue : [Paramètres de connexion S3](#). Vous pouvez configurer la manière dont le lecteur interprète les fichiers CSV dans votre `format_options`. Pour plus d'informations, consultez [CSV Configuration Reference](#) (Référence de configuration CSV).

Le script AWS Glue ETL suivant montre le processus de lecture de fichiers ou de dossiers CSV depuis S3.

Nous fournissons un lecteur CSV personnalisé avec des optimisations de performances pour les flux de travail courants à travers la clé de configuration `optimizePerformance`. Pour déterminer si ce lecteur est adapté à votre charge de travail, consultez [the section called “Utilisation d'un lecteur CSV optimisé”](#).

Python

Pour cet exemple, utilisez la méthode [create_dynamic_frame.from_options](#).

```
# Example: Read CSV from S3
# For show, we handle a CSV with a header row. Set the withHeader option.
# Consider whether optimizePerformance is right for your workflow.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
```

```
dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://s3path"]},
    format="csv",
    format_options={
        "withHeader": True,
        # "optimizePerformance": True,
    },
)
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read\
    .format("csv")\
    .option("header", "true")\
    .load("s3://s3path")
```

Scala

Pour cet exemple, utilisez l'opération [getSourceWithFormat](#).

```
// Example: Read CSV from S3
// For show, we handle a CSV with a header row. Set the withHeader option.
// Consider whether optimizePerformance is right for your workflow.

import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
    def main(sysArgs: Array[String]): Unit = {
        val spark: SparkContext = new SparkContext()
        val glueContext: GlueContext = new GlueContext(spark)

        val dynamicFrame = glueContext.getSourceWithFormat(
            formatOptions=JsonOptions("""{"withHeader": true}"""),
            connectionType="s3",
            format="csv",
            options=JsonOptions("""{"paths": ["s3://s3path"], "recurse": true}""")
        ).getDynamicFrame()
    }
}
```

Vous pouvez également l'utiliser DataFrames dans un script (`org.apache.spark.sql.DataFrame`).

```
val dataframe = spark.read
  .option("header", "true")
  .format("csv")
  .load("s3://s3path")
```

Exemple : écriture de fichiers et dossiers CSV dans S3

Prérequis : Vous aurez besoin d'un initialisé DataFrame (`dataFrame`) ou d'un DynamicFrame (`dynamicFrame`). Vous aurez également besoin de votre chemin de sortie S3, `s3path`.

Configuration : dans vos options de fonction, spécifiez `format="csv"`. Dans vos `connection_options`, utilisez la clé `paths` pour spécifier `s3path`. Vous pouvez configurer la manière dont le scripteur interagit avec S3 dans `connection_options`. Pour plus de détails, voir Types de connexion et options pour l'ETL dans AWS Glue : [Paramètres de connexion S3](#). Vous pouvez configurer la manière dont votre opération écrit le contenu de vos fichiers dans `format_options`. Pour plus d'informations, consultez [CSV Configuration Reference](#) (Référence de configuration CSV). Le script ETL AWS Glue suivant montre le processus d'écriture de fichiers et dossiers CSV vers S3.

Python

Pour cet exemple, utilisez la méthode [write_dynamic_frame.from_options](#).

```
# Example: Write CSV to S3
# For show, customize how we write string type values. Set quoteChar to -1 so our
# values are not quoted.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="s3",
    connection_options={"path": "s3://s3path"},
```

```
format="csv",
format_options={
    "quoteChar": -1,
},
)
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
dataFrame.write\
    .format("csv")\
    .option("quote", None)\
    .mode("append")\
    .save("s3://s3path")
```

Scala

Pour cet exemple, utilisez la méthode [getSinkWithFormat](#).

```
// Example: Write CSV to S3
// For show, customize how we write string type values. Set quoteChar to -1 so our
// values are not quoted.

import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    glueContext.getSinkWithFormat(
      connectionType="s3",
      options=JsonOptions("""{"path": "s3://s3path"}"""),
      format="csv"
    ).writeDynamicFrame(dynamicFrame)
  }
}
```

Vous pouvez également l'utiliser DataFrames dans un script (`org.apache.spark.sql.DataFrame`).


```
dataFrame.write
    .format("csv")
    .option("quote", null)
    .mode("Append")
    .save("s3://s3path")
```

Référence de configuration CSV

Vous pouvez utiliser ce qui suit `format_options` partout où les bibliothèques AWS Glue le spécifient `format="csv"` :

- `separator` – spécifie le caractère délimiteur. La valeur par défaut est une virgule, mais tout autre caractère peut être spécifié.
 - Type : texte, Valeur par défaut : `,`
- `escaper` – spécifie le caractère à utiliser pour l'échappement. Cette option est utilisée uniquement lors de la lecture de fichiers CSV, pas l'écriture. Si cette option est activée, le caractère qui suit immédiatement est utilisé tel quel, sauf pour un petit ensemble d'échappements connus (`\n`, `\r`, `\t` et `\0`).
 - Type : texte, Valeur par défaut : aucune
- `quoteChar` – spécifie le caractère à utiliser pour les guillemets. La valeur par défaut est les guillemets doubles. Définissez ce champ sur `-1` pour désactiver entièrement les guillemets.
 - Type : texte, Valeur par défaut : `' '`
- `multiLine` – spécifie si un même enregistrement peut couvrir plusieurs lignes. Cela peut se produire lorsqu'un champ contient un caractère de nouvelle ligne. Vous devez définir cette option sur `True` si aucun enregistrement ne s'étend sur plusieurs lignes. L'activation de `multiLine` peut réduire les performances, car elle nécessite un fractionnement plus prudent des fichiers lors de l'analyse.
 - Type : Booléen, Valeur par défaut : `false`
- `withHeader` – spécifie s'il convient de traiter la première ligne comme un en-tête. Cette option peut être utilisée dans la classe `DynamicFrameReader`.
 - Type : Booléen, Valeur par défaut : `false`
- `writeHeader` – spécifie s'il convient d'écrire l'en-tête dans la sortie. Cette option peut être utilisée dans la classe `DynamicFrameWriter`.
 - Type : Booléen, Valeur par défaut : `true`

- `skipFirst` – spécifie s'il convient d'ignorer la première ligne de données.
 - Type : Booléen, Valeur par défaut : `false`
- `optimizePerformance` –spécifie s'il faut utiliser le lecteur CSV SIMD avancé avec les formats de mémoire en colonnes basés sur Apache Arrow. Disponible uniquement en AWS Glue 3,0 et plus.
 - Type : Booléen, Valeur par défaut : `false`
- `strictCheckForQuoting`— Lors de l'écriture CSVs, Glue peut ajouter des guillemets aux valeurs qu'elle interprète comme des chaînes. Cela est fait pour éviter toute ambiguïté dans ce qui est écrit. Pour gagner du temps au moment de décider quoi écrire, Glue peut ajouter des guillemets dans certaines situations où ils ne sont pas nécessaires. L'activation d'une vérification stricte effectuera un calcul plus intensif et n'ajoutera de guillemets qu'en cas de nécessité absolue. Disponible uniquement en AWS Glue 3,0 et plus.
 - Type : Booléen, Valeur par défaut : `false`

Optimiser les performances de lecture avec un lecteur CSV SIMD vectorisé

AWS Glue la version 3.0 ajoute un lecteur CSV optimisé qui peut considérablement accélérer les performances globales du travail par rapport aux lecteurs CSV basés sur des lignes.

Le lecteur optimisé :

- utilise les instructions SIMD du processeur pour lire sur le disque
- écrit immédiatement les enregistrements en mémoire dans un format en colonnes (Apache Arrow)
- divise les enregistrements en lots

Cette méthode permet de gagner du temps de traitement lorsque les enregistrements sont ultérieurement regroupés ou convertis en format en colonnes. Certains exemples concernent la modification de schémas ou la récupération de données par colonne.

Pour utiliser le lecteur optimisé, définissez `"optimizePerformance"` sur `true` dans le `format_options` ou la propriété `table`.

```
glueContext.create_dynamic_frame.from_options(  
    frame = datasource1,  
    connection_type = "s3",  
    connection_options = {"paths": ["s3://s3path"]},  
    format = "csv",  
    format_options={
```

```
"optimizePerformance": True,  
"separator": ",",  
},  
transformation_ctx = "datasink2")
```

Limitations du lecteur CSV vectorisé

Notez les limitations suivantes du lecteur CSV vectorisé :

- Il ne prend pas en charge les options de formatage `multiLine` et `escape`. Il utilise la valeur par défaut `escape` du caractère guillemets doubles `' '`. Lorsque ces options sont définies, AWS Glue revient automatiquement à l'utilisation du lecteur CSV basé sur les lignes.
- Il ne prend pas en charge la création d'un `DynamicFrame` avec [ChoiceType](#).
- Il ne prend pas en charge la création d'un `DynamicFrame` avec des [enregistrements d'erreur](#).
- Il ne prend pas en charge la lecture de fichiers CSV contenant des caractères multioctets tels que des caractères japonais ou chinois.

Utilisation du format Parquet dans AWS Glue

AWS Glue récupère les données des sources et écrit les données sur des cibles stockées et transportées dans différents formats de données. Si vos données sont stockées ou transportées au format de données Parquet, ce document présente les fonctionnalités disponibles pour utiliser vos données dans AWS Glue.

AWS Supports à colle au format Parquet. Ce format est un format de données en colonnes, orienté vers la performance. Pour accéder à une présentation du format par l'autorité standard, consultez [Apache Parquet Documentation Overview](#) (Présentation de la documentation Apache Parquet).

Vous pouvez utiliser AWS Glue pour lire des fichiers Parquet depuis Amazon S3 et depuis des sources de streaming, ainsi que pour écrire des fichiers Parquet sur Amazon S3. Vous pouvez lire et écrire des archives bzip et gzip contenant des fichiers Parquet provenant de S3. Vous configurez le comportement de compression sur [Paramètres de connexion S3](#) plutôt que dans la configuration décrite sur cette page.

Le tableau suivant indique les fonctionnalités courantes de AWS Glue compatibles avec l'option de format Parquet.

Lecture	Écrire	Lecture en streaming	Groupement des petits fichiers	Signets de tâche
Pris en charge	Pris en charge	Pris en charge	Non pris en charge	Pris en charge [*]

* Supporté dans la version 1.0+ de AWS Glue

Exemple : lecture de fichiers ou dossiers Parquet depuis S3

Prérequis : vous aurez besoin des chemins S3 (s3path) vers des fichiers ou dossiers Parquet que vous souhaitez lire.

Configuration : dans vos options de fonction, spécifiez `format="parquet"`. Dans vos `connection_options`, utilisez la clé `paths` pour spécifier votre s3path.

Vous pouvez configurer la manière dont le lecteur interagit avec S3 dans les `connection_options`. Pour plus de détails, voir Types de connexion et options pour l'ETL dans AWS Glue : [Paramètres de connexion S3](#).

Vous pouvez configurer la manière dont le lecteur interprète les fichiers Parquet dans votre `format_options`. Pour plus d'informations, consultez [Parquet Configuration Reference](#) (Référence de configuration Parquet).

Le script AWS Glue ETL suivant montre le processus de lecture des fichiers ou dossiers Parquet depuis S3 :

Python

Pour cet exemple, utilisez la méthode [create_dynamic_frame.from_options](#).

```
# Example: Read Parquet from S3

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
```

```
dynamicFrame = glueContext.create_dynamic_frame.from_options(  
    connection_type = "s3",  
    connection_options = {"paths": ["s3://s3path/" ]},  
    format = "parquet"  
)
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read.parquet("s3://s3path/")
```

Scala

Pour cet exemple, utilisez la méthode [getSourceWithFormat](#).

```
// Example: Read Parquet from S3  
  
import com.amazonaws.services.glue.util.JsonOptions  
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}  
import org.apache.spark.SparkContext  
  
object GlueApp {  
    def main(sysArgs: Array[String]): Unit = {  
        val spark: SparkContext = new SparkContext()  
        val glueContext: GlueContext = new GlueContext(spark)  
  
        val dynamicFrame = glueContext.getSourceWithFormat(  
            connectionType="s3",  
            format="parquet",  
            options=JsonOptions("""{"paths": ["s3://s3path"]}""")  
        ).getDynamicFrame()  
    }  
}
```

Vous pouvez également l'utiliser DataFrames dans un script (`org.apache.spark.sql.DataFrame`).

```
spark.read.parquet("s3://s3path/")
```

Exemple : écriture de fichiers et dossiers Parquet dans S3

Prérequis : Vous aurez besoin d'un initialisé DataFrame (dataFrame) ou DynamicFrame (dynamicFrame). Vous aurez également besoin de votre chemin de sortie S3, s3path.

Configuration : dans vos options de fonction, spécifiez format="parquet". Dans vos connection_options, utilisez la clé paths pour spécifier s3path.

Vous pouvez modifier davantage la manière dont le scripteur interagit avec S3 dans les connection_options. Pour plus de détails, voir Types de connexion et options pour l'ETL dans AWS Glue : [Paramètres de connexion S3](#). Vous pouvez configurer la manière dont votre opération écrit le contenu de vos fichiers dans format_options. Pour plus d'informations, consultez [Parquet Configuration Reference](#) (Référence de configuration Parquet).

Le script AWS Glue ETL suivant montre le processus d'écriture de fichiers et de dossiers Parquet dans S3.

Nous fournissons un rédacteur de parquet personnalisé avec des optimisations de performances DynamicFrames, grâce à la clé de useGlueParquetWriter configuration. Pour déterminer si ce scripteur est adapté à votre charge de travail, consultez [Glue Parquet Writer](#) (Scripteur Parquet Glue).

Python

Pour cet exemple, utilisez la méthode [write_dynamic_frame.from_options](#).

```
# Example: Write Parquet to S3
# Consider whether useGlueParquetWriter is right for your workflow.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="s3",
    format="parquet",
    connection_options={
        "path": "s3://s3path",
```

```
    },  
    format_options={  
        # "useGlueParquetWriter": True,  
    },  
)
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
df.write.parquet("s3://s3path/")
```

Scala

Pour cet exemple, utilisez la méthode [getSinkWithFormat](#).

```
// Example: Write Parquet to S3  
// Consider whether useGlueParquetWriter is right for your workflow.  
  
import com.amazonaws.services.glue.util.JsonOptions  
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}  
import org.apache.spark.SparkContext  
  
object GlueApp {  
  def main(sysArgs: Array[String]): Unit = {  
    val spark: SparkContext = new SparkContext()  
    val glueContext: GlueContext = new GlueContext(spark)  
  
    glueContext.getSinkWithFormat(  
      connectionType="s3",  
      options=JsonOptions("""{"path": "s3://s3path"}"""),  
      format="parquet"  
    ).writeDynamicFrame(dynamicFrame)  
  }  
}
```

Vous pouvez également l'utiliser DataFrames dans un script (`org.apache.spark.sql.DataFrame`).

```
df.write.parquet("s3://s3path/")
```

Référence de configuration Parquet

Vous pouvez utiliser ce qui suit `format_options` partout où les bibliothèques AWS Glue le spécifient `format="parquet"` :

- `useGlueParquetWriter`— Spécifie l'utilisation d'un rédacteur Parquet personnalisé doté d'optimisations des performances pour `DynamicFrame` les flux de travail. Pour plus d'informations, consultez [Glue Parquet Writer](#) (Scripteur Parquet Glue).
 - Type : Booléen, Valeur par défaut : `false`
- `compression` – spécifie le codec de compression utilisé. Les valeurs sont entièrement compatibles avec `org.apache.parquet.hadoop.metadata.CompressionCodecName`.
 - Type : Texte énuméré, Valeur par défaut : `"snappy"`
 - Valeurs : `"uncompressed"`, `"snappy"`, `"gzip"`, et `"lzo"`
- `blockSize` – spécifie la taille en octets d'un groupe de lignes mis en mémoire. Vous l'utilisez pour régler les performances. La taille doit être divisée exactement en un certain nombre de mégaoctets.
 - Type : Numérique, Valeur par défaut : `134217728`
 - La valeur par défaut est égale à 128 Mo.
- `pageSize` – spécifie la taille d'une page en octets. Vous l'utilisez pour régler les performances. Une page est la plus petite unité qui doit être lue entièrement pour accéder à un enregistrement unique.
 - Type : Numérique, Valeur par défaut : `1048576`
 - La valeur par défaut est égale à 1 Mo.

Note

De plus, toutes les options acceptées par le code SparkSQL sous-jacent peuvent être transmises à ce format via le paramètre `map connection_options`. Par exemple, vous pouvez définir une configuration Spark telle que [MergeSchema](#) pour AWS Glue Lecteur Spark pour fusionner le schéma de tous les fichiers.

Optimiser les performances d'écriture avec le scripteur AWS Glue Parquet

Note

Le rédacteur AWS Glue Parquet a toujours été accessible via le type de `glueparquet` format. Ce modèle d'accès n'est plus préconisé. Utilisez plutôt le type `parquet` avec `useGlueParquetWriter` activé.

Le logiciel de AWS gravure Glue Parquet présente des améliorations de performances qui permettent d'écrire plus rapidement les fichiers Parquet. Le scripteur traditionnel calcule un schéma avant d'écrire. Le format Parquet ne stocke pas le schéma de manière rapidement récupérable, ce qui peut prendre un certain temps. Avec le rédacteur AWS Glue Parquet, aucun schéma précalculé n'est requis. Au fur et à mesure que les données sont introduites, le scripteur calcule et modifie le schéma de manière dynamique.

Notez les limitations suivantes lorsque vous spécifiez `useGlueParquetWriter` :

- Le dispositif d'écriture prend uniquement en charge l'évolution du schéma, comme l'ajout ou la suppression de colonnes, mais pas la modification des types de colonnes, par exemple avec `ResolveChoice`.
- Le rédacteur ne prend pas en charge l'écriture vide `DataFrames`, par exemple pour écrire un fichier contenant uniquement des schémas. Lors de l'intégration au catalogue de données AWS Glue via un paramètre `enableUpdateCatalog=True`, toute tentative d'écriture d'un fichier vide ne `DataFrame` mettra pas à jour le catalogue de données. Cela entraînera la création d'une table sans schéma dans le catalogue de données.

Si votre transformation ne nécessite pas ces limitations, l'activation de la machine de gravure AWS Glue Parquet devrait améliorer les performances.

Utilisation du format XML dans AWS Glue

AWS Glue récupère les données des sources et écrit les données sur des cibles stockées et transportées dans différents formats de données. Si vos données sont stockées ou transportées au format de données XML, ce document présente les fonctionnalités disponibles pour utiliser vos données dans AWS Glue.

AWS Glue prend en charge l'utilisation du format XML. Ce format représente des structures de données hautement configurables et définies de manière rigide qui ne sont pas basées sur des lignes

ou des colonnes. Le XML est hautement standardisé. Pour accéder à une présentation du format par l'autorité standard, consultez [XML Essentials](#) (Essentiels XML).

Vous pouvez utiliser AWS Glue pour lire des fichiers XML depuis Amazon S3, ainsi que bzip des gzip archives contenant des fichiers XML. Vous configurez le comportement de compression sur [Paramètres de connexion S3](#) plutôt que dans la configuration décrite sur cette page.

Le tableau suivant indique les fonctionnalités courantes de AWS Glue compatibles avec l'option de format XML.

Lecture	Écrire	Lecture en streaming	Groupement des petits fichiers	Signets de tâche
Pris en charge	Non pris en charge	Non pris en charge	Pris en charge	Pris en charge

Exemple : lecture de XML depuis S3

Le lecteur XML prend un nom de balise XML. Il examine les éléments comportant cette balise dans son entrée pour en déduire un schéma et remplit un `DynamicFrame` avec les valeurs correspondantes. La fonctionnalité AWS Glue XML se comporte de la même manière que la [source de données XML pour Apache Spark](#). Vous pourriez être en mesure de mieux comprendre le comportement de base en comparant ce lecteur à la documentation de ce projet.

Prérequis : Vous aurez besoin des chemins S3 (`s3path`) vers les fichiers ou dossiers XML que vous souhaitez lire, ainsi qu'à certaines informations concernant votre fichier XML. Vous aurez également besoin de la balise pour l'élément XML que vous souhaitez lire, `xmlTag`.

Configuration : dans vos options de fonction, spécifiez `format="xml"`. Dans vos `connection_options`, utilisez la clé `paths` pour spécifier `s3path`. Vous pouvez configurer plus en détail la manière dont le lecteur interagit avec S3 dans le `connection_options`. Pour plus de détails, voir Types de connexion et options pour l'ETL dans AWS Glue : [Paramètres de connexion S3](#). Dans vos `format_options`, utilisez la clé `rowTag` pour spécifier `xmlTag`. Vous pouvez configurer plus en détail la façon dont le lecteur interprète les fichiers XML dans votre `format_options`. Pour plus d'informations, consultez [XML Configuration Reference](#) (Référence de configuration XML).

Le script AWS Glue ETL suivant montre le processus de lecture de fichiers ou dossiers XML à partir de S3.

Python

Pour cet exemple, utilisez la méthode [create_dynamic_frame.from_options](#).

```
# Example: Read XML from S3
# Set the rowTag option to configure the reader.

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://s3path"]},
    format="xml",
    format_options={"rowTag": "xmlTag"},
)
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read\
    .format("xml")\
    .option("rowTag", "xmlTag")\
    .load("s3://s3path")
```

Scala

Pour cet exemple, utilisez l'opération [getSourceWithFormat](#).

```
// Example: Read XML from S3
// Set the rowTag option to configure the reader.

import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.GlueContext
import org.apache.spark.sql.SparkSession

val glueContext = new GlueContext(SparkContext.getOrCreate())
val sparkSession: SparkSession = glueContext.getSparkSession

object GlueApp {
```

```
def main(sysArgs: Array[String]): Unit = {
    val dynamicFrame = glueContext.getSourceWithFormat(
        formatOptions=JsonOptions("""{"rowTag": "xmlTag"}"""),
        connectionType="s3",
        format="xml",
        options=JsonOptions("""{"paths": ["s3://s3path"], "recurse": true}""")
    ).getDynamicFrame()
}
```

Vous pouvez également l'utiliser DataFrames dans un script (org.apache.spark.sql.DataFrame).

```
val dataframe = spark.read
    .option("rowTag", "xmlTag")
    .format("xml")
    .load("s3://s3path")
```

Référence de configurations XML

Vous pouvez utiliser ce qui suit format_options partout où les bibliothèques AWS Glue le spécifient format="xml" :

- rowTag – spécifie la balise XML du fichier à traiter comme ligne. Les balises de ligne ne se ferment pas automatiquement.
 - Type : Texte, Obligatoire
- encoding – spécifie le codage de caractère. Il peut s'agir du nom ou de l'alias d'un [Charset](#) pris en charge par notre environnement d'exécution. Nous ne donnons pas de garanties spécifiques concernant la prise en charge de l'encodage, mais les principaux codages devraient fonctionner.
 - Type : texte, Valeur par défaut : "UTF-8"
- excludeAttribute – spécifie si vous souhaitez ou pas exclure les attributs dans les éléments.
 - Type : Booléen, Valeur par défaut : false
- treatEmptyValuesAsNulls – spécifie s'il convient de traiter un espace blanc comme valeur nulle.
 - Type : Booléen, Valeur par défaut : false
- attributePrefix – Un préfixe des attributs pour les différencier des éléments. Ce préfixe est utilisé pour les noms de champs.

- Type : texte, Valeur par défaut : "_"
- valueTag – La balise utilisée pour une valeur lorsqu'il y a des attributs de l'élément qui n'ont pas d'enfant.
 - Type : texte, Valeur par défaut : "_VALUE"
- ignoreSurroundingSpaces – spécifie si les espaces blancs qui entourent les valeurs doivent être ignorés.
 - Type : Booléen, Valeur par défaut : false
- withSchema – Contient le schéma attendu, dans les cas où vous souhaitez remplacer le schéma déduit. Si vous n'utilisez pas cette option, AWS Glue déduit le schéma à partir des données XML.
 - Type : Texte, Par défaut: Non applicable
 - La valeur doit être un objet JSON qui représente un StructType.

Spécifier manuellement le schéma XML

Exemple de schéma XML manuel

Il s'agit d'un exemple d'utilisation de l'option format withSchema pour spécifier le schéma des données XML.

```
from awsglue.gluetypes import *

schema = StructType([
    Field("id", IntegerType()),
    Field("name", StringType()),
    Field("nested", StructType([
        Field("x", IntegerType()),
        Field("y", StringType()),
        Field("z", ChoiceType([IntegerType(), StringType()]))
    ]))
])

datasource0 = create_dynamic_frame_from_options(
    connection_type,
    connection_options={"paths": ["s3://xml_bucket/someprefix"]},
    format="xml",
    format_options={"withSchema": json.dumps(schema.jsonValue())},
    transformation_ctx = ""
)
```

Utilisation du format Avro dans Glue AWS

AWS Glue récupère les données des sources et écrit les données sur des cibles stockées et transportées dans différents formats de données. Si vos données sont stockées ou transportées au format de données Avro, ce document présente les fonctionnalités disponibles pour utiliser vos données dans AWS Glue.

AWS Glue supporte l'utilisation du format Avro. Ce format est un format de données en colonnes et orienté vers la performance. Pour accéder à une présentation du format par l'autorité standard, consultez [documentation Apache Avro 1.8.2](#).

Vous pouvez utiliser AWS Glue pour lire des fichiers Avro depuis Amazon S3 et depuis des sources de streaming, ainsi que pour écrire des fichiers Avro sur Amazon S3. Vous pouvez lire et écrire bzip2 et gzip des archives contenant des fichiers Avro provenant de S3. De plus, vous pouvez écrire des archives deflate, snappy et xz contenant des fichiers Avro. Vous configurez le comportement de compression sur [Paramètres de connexion S3](#) plutôt que dans la configuration décrite sur cette page.

Le tableau suivant indique quelles opérations AWS Glue courantes prennent en charge l'option de format Avro.

Lecture	Écrire	Lecture en streaming	Groupement des petits fichiers	Signets de tâche
Pris en charge	Pris en charge	Pris en charge [*]	Non pris en charge	Pris en charge

^{*} Pris en charge avec des restrictions. Pour de plus amples informations, veuillez consulter [the section called "Notes et restrictions pour les sources en streaming Avro"](#).

Exemple : lecture de fichiers Avro ou de dossiers de S3

Prérequis : vous aurez besoin des chemins S3 (s3path) vers des fichiers ou dossiers Avro que vous souhaitez lire.

Configuration : dans vos options de fonction, spécifiez format="avro". Dans vos connection_options, utilisez la clé paths pour spécifier s3path. Vous pouvez configurer la manière dont le lecteur interagit avec S3 dans les connection_options. Pour plus de détails, voir Options de format de données pour les entrées et sorties ETL dans AWS Glue : [the section](#)

called [“Paramètres de connexion S3”](#). Vous pouvez configurer la manière dont le lecteur interprète les fichiers Avro dans votre `format_options`. Pour plus d'informations, consultez [Référence de configuration Avro](#).

Le script AWS Glue ETL suivant montre le processus de lecture de fichiers ou de dossiers Avro depuis S3 :

Python

Pour cet exemple, utilisez la méthode [create_dynamic_frame.from_options](#).

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://s3path"]},
    format="avro"
)
```

Scala

Pour cet exemple, utilisez l'opération [getSourceWithFormat](#).

```
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.GlueContext
import org.apache.spark.sql.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType="s3",
      format="avro",
      options=JsonOptions("""{"paths": ["s3://s3path"]}""")
    ).getDynamicFrame()
  }
}
```

Exemple : écriture de fichiers et dossiers Avro dans S3

Prérequis : Vous aurez besoin d'un initialisé DataFrame (dataFrame) ou DynamicFrame (dynamicFrame). Vous aurez également besoin de votre chemin de sortie S3, s3path.

Configuration : dans vos options de fonction, spécifiez format="avro". Dans vos connection_options, utilisez la clé paths pour spécifier votre s3path. Vous pouvez modifier davantage la manière dont le scripteur interagit avec S3 dans les connection_options. Pour plus de détails, voir Options de format de données pour les entrées et sorties ETL dans AWS Glue : [the section called "Paramètres de connexion S3"](#). Vous pouvez modifier la façon dont le rédacteur interprète les fichiers Avro dans votre format_options. Pour plus d'informations, consultez [Référence de configuration Avro](#).

Le script AWS Glue ETL suivant montre le processus d'écriture de fichiers ou de dossiers Avro dans S3.

Python

Pour cet exemple, utilisez la méthode [write_dynamic_frame.from_options](#).

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="s3",
    format="avro",
    connection_options={
        "path": "s3://s3path"
    }
)
```

Scala

Pour cet exemple, utilisez la méthode [getSinkWithFormat](#).

```
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext
```



```
object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    glueContext.getSinkWithFormat(
      connectionType="s3",
      options=JsonOptions("""{"path": "s3://s3path"}"""),
      format="avro"
    ).writeDynamicFrame(dynamicFrame)
  }
}
```

Référence de configurations Avro

Vous pouvez utiliser les `format_options` valeurs suivantes partout où les bibliothèques AWS Glue le spécifient `format="avro"` :

- **version** — spécifie la version du format de lecture/écriture Apache Avro à prendre en charge. La valeur par défaut est 1.7. Vous pouvez spécifier `format_options={"version": "1.8"}` pour activer la lecture et l'écriture d'un type logique Avro. Pour plus d'informations, consultez les [spécifications Apache Avro 1.7.7](#) et les [spécifications Apache Avro 1.8.2](#).

Le connecteur Apache Avro 1.8 prend en charge les conversions de type logique suivantes :

Pour le lecteur : ce tableau montre la conversion entre le type de données Avro (type logique et type primitif Avro) et AWS Glue `DynamicFrame` type de données pour Avro Reader 1.7 et 1.8.

Type de données Avro :	Type de données Avro :	GlueDynamicFrame Type de données :	GlueDynamicFrame Type de données :
Type logique	Type Avro primitif	Avro Reader 1.7	Avro Reader 1.8
Décimal	octets	BINAIRE	Décimal
Décimal	corrigé(e)(s)	BINAIRE	Décimal
Date	int	INT	Date

Type de données Avro :	Type de données Avro :	GlueDynamicFrame Type de données :	GlueDynamicFrame Type de données :
Type logique	Type Avro primitif	Avro Reader 1.7	Avro Reader 1.8
Temps (milliseconde)	int	INT	INT
Temps (microseconde)	long	LONG	LONG
Horodatage (milliseconde)	long	LONG	Horodatage
Horodatage (microseconde)	long	LONG	LONG
Durée (pas un type logique)	corrigé(e)(s) sur 12	BINAIRE	BINAIRE

Pour le rédacteur : ce tableau montre la conversion entre AWS Glue DynamicFrame type de données et type de données Avro pour Avro Writer 1.7 et 1.8.

AWS Glue Type de données DynamicFrame	Type de données Avro : Avro Writer 1.7	Type de données Avro : Avro Writer 1.8
Décimal	Chaîne	decimal
Date	Chaîne	date
Horodatage	Chaîne	timestamp-micros

Assistance Avro Spark DataFrame

Pour utiliser Avro depuis l' API DataFrame Spark, vous devez installer le plugin Spark Avro pour la version de Spark correspondante. La version de Spark disponible dans votre tâche est déterminée par votre version de AWS Glue. Pour plus d'informations sur les versions Spark, consultez [the](#)

[section called “AWS Glue versions”](#). Ce plugin est maintenu par Apache, nous ne donnons pas de garanties spécifiques de support.

Dans AWS Glue 2.0, utilisez la version 2.4.3 du plugin Spark Avro. Vous pouvez trouver ce fichier JAR sur Maven Central, voir [org.apache.spark:spark-avro_2.12:2.4.3](#).

Dans AWS Glue 3.0, utilisez la version 3.1.1 du plugin Spark Avro. Vous pouvez trouver ce fichier JAR sur Maven Central, voir [org.apache.spark : spark-avro_2.12:3.1.1](#).

Pour inclure des éléments supplémentaires JARs dans une tâche AWS Glue ETL, utilisez le paramètre `--extra-jars job`. Pour de plus amples informations sur la définition des paramètres de la tâche, consultez [the section called “Paramètres des tâches”](#). Vous pouvez également configurer ce paramètre dans AWS Management Console.

Utilisation du format GrokLog dans Glue AWS

AWS Glue récupère les données des sources et écrit les données sur des cibles stockées et transportées dans différents formats de données. Si vos données sont stockées ou transportées dans un format de texte brut peu structuré, ce document présente les fonctionnalités disponibles pour utiliser vos données dans les modèles AWS Glue through Grok.

AWS Supports à colle utilisant des motifs Grok. Les modèles Grok sont similaires aux groupes de capture d'expressions régulières. Ils reconnaissent les modèles de séquences de caractères dans un fichier texte brut et leur donnent un type et un objectif. Dans AWS Glue, leur objectif principal est de lire les journaux. Pour une introduction au Grok par les auteurs, voir [Référence Logstash : plug-in de filtre Grok](#).

Lecture	Écrire	Lecture en streaming	Groupe ment des petits fichiers	Signets de tâche
Pris en charge	Ne s'applique pas	Pris en charge	Pris en charge	Non pris en charge

Référence de configuration grokLog

Vous pouvez utiliser les valeurs `format_options` suivantes avec `format="grokLog"` :

- `logFormat` — spécifie le modèle Grok correspondant au format du journal.
- `customPatterns` — spécifie les modèles Grok supplémentaires utilisés ici.

- **MISSING** — spécifie le signal à utiliser lors de l'identification des valeurs manquantes. L'argument par défaut est ' - '.
- **LineCount** — spécifie le nombre de lignes de chaque enregistrement de journal. La valeur par défaut est '1', et actuellement seuls les enregistrements d'une ligne sont pris en charge.
- **StrictMode** — valeur booléenne indiquant si le mode strict est activé. En mode strict, le lecteur n'exécute pas de conversion ou récupération de type automatique. La valeur par défaut est "false".

Utilisation du format Ion dans AWS Glue

AWS Glue récupère les données des sources et écrit les données sur des cibles stockées et transportées dans différents formats de données. Si vos données sont stockées ou transportées au format de données Ion, ce document présente les fonctionnalités disponibles pour utiliser vos données dans AWS Glue.

AWS Glue supporte l'utilisation du format Ion. Ce format représente des structures de données (qui ne sont pas basées sur des lignes ou des colonnes) dans des représentations binaires et en texte brut interchangeables. Pour accéder à une présentation du format par les auteurs, consultez [Amazon Ion](#). (Pour plus d'informations, consultez la [spécification Amazon Ion](#).)

Vous pouvez utiliser AWS Glue pour lire les fichiers Ion depuis Amazon S3. Vous pouvez lire `gzip` et des archives contenant des fichiers Ion provenant de S3. Vous configurez le comportement de compression sur [Paramètres de connexion S3](#) plutôt que dans la configuration décrite sur cette page.

Le tableau suivant indique quelles opérations AWS Glue courantes prennent en charge l'option de format Ion.

Lecture	Écrire	Lecture en streaming	Groupement des petits fichiers	Signets de tâche
Pris en charge	Non pris en charge	Non pris en charge	Pris en charge	Non pris en charge

Exemple : lecture de fichiers ou de dossiers Ion de S3

Prérequis : vous aurez besoin des chemins S3 (`s3path`) vers des fichiers ou dossiers Ion que vous souhaitez lire.

Configuration : dans vos options de fonction, spécifiez `format="json"`. Dans vos `connection_options`, utilisez la clé `paths` pour spécifier votre `s3path`. Vous pouvez configurer la manière dont le lecteur interagit avec S3 dans les `connection_options`. Pour plus de détails, voir Types de connexion et options pour l'ETL dans AWS Glue : [the section called “Paramètres de connexion S3”](#).

Le script AWS Glue ETL suivant montre le processus de lecture de fichiers ou de dossiers Ion depuis S3 :

Python

Pour cet exemple, utilisez la méthode [create_dynamic_frame.from_options](#).

```
# Example: Read ION from S3

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://s3path"]},
    format="ion"
)
```

Scala

Pour cet exemple, utilisez l'opération [getSourceWithFormat](#).

```
// Example: Read ION from S3

import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.GlueContext
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    val dynamicFrame = glueContext.getSourceWithFormat(
```

```

        connectionType="s3",
        format="ion",
        options=JsonOptions("""{"paths": ["s3://s3path"], "recurse": true}""")
    ).getDynamicFrame()
}
}

```

Référence de configurations Ion

Il n'y a aucune valeur `format_options` pour `format="ion"`.

Utilisation du format JSON dans AWS Glue

AWS Glue récupère les données des sources et écrit les données sur des cibles stockées et transportées dans différents formats de données. Si vos données sont stockées ou transportées au format JSON, ce document vous présente les fonctionnalités disponibles pour utiliser vos données dans AWS Glue.

AWS Glue prend en charge l'utilisation du format JSON. Ce format représente des structures de données avec une forme uniforme mais un contenu flexible qui ne sont pas basés sur des lignes ou des colonnes. Le JSON est défini par des normes parallèles émises par plusieurs autorités, dont l'ECMA-404. Pour accéder à une présentation du format par une source fréquemment référencée, consultez [Introducing JSON](#) (Présentation de JSON).

Vous pouvez utiliser AWS Glue pour lire des fichiers JSON depuis Amazon S3, ainsi que bzip des fichiers JSON gzip compressés. Vous configurez le comportement de compression sur [Paramètres de connexion S3](#) plutôt que dans la configuration décrite sur cette page.

Lecture	Écrire	Lecture en streaming	Grouperement des petits fichiers	Signets de tâche	
Pris en charge	Pris en charge	Pris en charge	Pris en charge	Pris en charge	

Exemple : lecture de fichiers ou de dossiers JSON de S3

Prérequis : vous aurez besoin des chemins S3 (`s3path`) vers des fichiers ou dossiers JSON que vous souhaitez lire.

Configuration : dans vos options de fonction, spécifiez `format="json"`. Dans vos `connection_options`, utilisez la clé `paths` pour spécifier votre `s3path`. Vous pouvez également modifier la façon dont votre opération de lecture traversera `s3` dans les options de connexion, consultez [the section called “Paramètres de connexion S3”](#) pour plus d'informations. Vous pouvez configurer la manière dont le lecteur interprète les fichiers JSON dans votre `format_options`. Pour plus d'informations, consultez [JSON Configuration Reference](#) (Référence de configuration JSON).

Le script AWS Glue ETL suivant montre le processus de lecture de fichiers ou de dossiers JSON depuis S3 :

Python

Pour cet exemple, utilisez la méthode [create_dynamic_frame.from_options](#).

```
# Example: Read JSON from S3
# For show, we handle a nested JSON file that we can limit with the JsonPath
# parameter
# For show, we also handle a JSON where a single entry spans multiple lines
# Consider whether optimizePerformance is right for your workflow.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://s3path"]},
    format="json",
    format_options={
        "jsonPath": "$.id",
        "multiline": True,
        # "optimizePerformance": True, -> not compatible with jsonPath, multiline
    }
)
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read\
    .option("multiline", "true")\
```

```
.json("s3://s3path")
```

Scala

Pour cet exemple, utilisez l'opération [getSourceWithFormat](#).

```
// Example: Read JSON from S3
// For show, we handle a nested JSON file that we can limit with the JsonPath
// parameter
// For show, we also handle a JSON where a single entry spans multiple lines
// Consider whether optimizePerformance is right for your workflow.

import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    val dynamicFrame = glueContext.getSourceWithFormat(
      formatOptions=JsonOptions("""{"jsonPath": "$.id", "multiline": true,
"optimizePerformance":false}"""),
      connectionType="s3",
      format="json",
      options=JsonOptions("""{"paths": ["s3://s3path"], "recurse": true}""")
    ).getDynamicFrame()
  }
}
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
val dataFrame = spark.read
  .option("multiline", "true")
  .json("s3://s3path")
```

Exemple : écriture de fichiers et dossiers JSON dans S3

Prérequis : Vous aurez besoin d'un initialisé DataFrame (`dataFrame`) ou DynamicFrame (`dynamicFrame`). Vous aurez également besoin de votre chemin de sortie S3, `s3path`.

Configuration : dans vos options de fonction, spécifiez `format="json"`. Dans vos `connection_options`, utilisez la clé `paths` pour spécifier `s3path`. Vous pouvez modifier davantage la manière dont le scripteur interagit avec S3 dans les `connection_options`. Pour plus de détails, voir Options de format de données pour les entrées et sorties ETL dans AWS Glue :[the section called “Paramètres de connexion S3”](#). Vous pouvez configurer la manière dont le lecteur interprète les fichiers JSON dans votre `format_options`. Pour plus d'informations, consultez [JSON Configuration Reference](#) (Référence de configuration JSON).

Le script AWS Glue ETL suivant montre le processus d'écriture de fichiers ou de dossiers JSON à partir de S3 :

Python

Pour cet exemple, utilisez la méthode [write_dynamic_frame.from_options](#).

```
# Example: Write JSON to S3

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="s3",
    connection_options={"path": "s3://s3path"},
    format="json"
)
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
df.write.json("s3://s3path/")
```

Scala

Pour cet exemple, utilisez la méthode [getSinkWithFormat](#).

```
// Example: Write JSON to S3

import com.amazonaws.services.glue.util.JsonOptions
```

```
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    glueContext.getSinkWithFormat(
      connectionType="s3",
      options=JsonOptions("""{"path": "s3://s3path"}"""),
      format="json"
    ).writeDynamicFrame(dynamicFrame)
  }
}
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
df.write.json("s3://s3path")
```

Référence de configurations Json

Vous pouvez utiliser les valeurs `format_options` suivantes avec `format="json"` :

- `jsonPath`— [JsonPath](#) Expression qui identifie un objet à lire dans des enregistrements. Cette expression est particulièrement utile lorsqu'un fichier contient des enregistrements imbriqués à l'intérieur d'un tableau externe. Par exemple, l' `JsonPath` expression suivante cible le `id` champ d'un objet JSON.

```
format="json", format_options={"jsonPath": "$.id"}
```

- `multiline` — valeur booléenne qui spécifie si un même enregistrement peut couvrir plusieurs lignes. Cela peut se produire lorsqu'un champ contient un caractère de nouvelle ligne. Vous devez définir cette option sur `"true"` si aucun enregistrement ne s'étend sur plusieurs lignes. La valeur par défaut est `"false"`, qui permet un fractionnement en fichiers plus agressif pendant l'analyse.
- `optimizePerformance` — valeur booléenne qui spécifie s'il faut utiliser le lecteur CSV SIMD avancé avec les formats de mémoire en colonnes basés sur Apache Arrow. Disponible uniquement en AWS Glue 3,0. Non compatible avec `multiline` ou `jsonPath`. Si vous fournissez l'une ou l'autre de ces options, AWS Glue sera obligée de revenir au lecteur standard.

- `withSchema` — Une valeur String qui spécifie un schéma de table au format décrit dans [the section called “Spécifier le schéma XML”](#). Utilisé uniquement avec `optimizePerformance` lors de la lecture à partir de connexions hors catalogue.

Utilisation d'un lecteur CSV SIMD vectorisé avec le format en colonnes Apache Arrow

AWS Glue la version 3.0 ajoute un lecteur vectorisé pour les données JSON. Il fonctionne deux fois plus vite dans certaines conditions que le lecteur standard. Ce lecteur est livré avec certaines limitations dont les utilisateurs doivent être conscients avant utilisation, décrites dans cette section.

Pour utiliser le lecteur optimisé, définissez `"optimizePerformance"` sur `True` dans le `format_options` ou la propriété table. Vous devrez également fournir `withSchema` sauf si vous lisez le catalogue. `withSchema` attend une entrée comme décrit dans le [the section called “Spécifier le schéma XML”](#).

```
// Read from S3 data source
glueContext.create_dynamic_frame.from_options(
    connection_type = "s3",
    connection_options = {"paths": ["s3://s3path"]},
    format = "json",
    format_options={
        "optimizePerformance": True,
        "withSchema": SchemaString
    })

// Read from catalog table
glueContext.create_dynamic_frame.from_catalog(
    database = database,
    table_name = table,
    additional_options = {
        // The vectorized reader for JSON can read your schema from a catalog table
        // property.
        "optimizePerformance": True,
    })
```

Pour plus d'informations sur la création d'un *SchemaString* dans la bibliothèque AWS Glue, consultez [the section called “Types”](#).

Limitations du lecteur CSV vectorisé

Prenez en compte les limitations suivantes :

- Les éléments JSON avec des objets imbriqués ou des valeurs de tableau ne sont pas pris en charge. S'il est fourni, AWS Glue retournera au lecteur standard.
- Un schéma doit être fourni, soit à partir du catalogue, soit avec `withSchema`.
- Non compatible avec `multiline` ou `jsonPath`. Si vous fournissez l'une ou l'autre de ces options, AWS Glue sera obligée de revenir au lecteur standard.
- Le fait de fournir des enregistrements d'entrée qui ne correspondent pas au schéma d'entrée entraînera un dysfonctionnement du lecteur.
- [Les enregistrements d'erreurs](#) ne seront pas créés.
- Les fichiers JSON contenant des caractères à plusieurs octets (tels que les caractères japonais ou chinois) ne sont pas pris en charge.

Utilisation du format ORC dans Glue AWS

AWS Glue récupère les données des sources et écrit les données sur des cibles stockées et transportées dans différents formats de données. Si vos données sont stockées ou transportées au format ORC, ce document présente les fonctionnalités disponibles pour utiliser vos données dans AWS Glue.

AWS Glue supporte l'utilisation du format ORC. Ce format est un format de données en colonnes, orienté vers la performance. Pour accéder à une présentation du format par l'autorité standard, consultez [Apache Orc](#).

Vous pouvez utiliser AWS Glue pour lire des fichiers ORC depuis Amazon S3 et depuis des sources de streaming, ainsi que pour écrire des fichiers ORC sur Amazon S3. Vous pouvez lire et écrire des archives `bzip` et `gzip` contenant des fichiers CSV provenant de S3. Vous configurez le comportement de compression sur [Paramètres de connexion S3](#) plutôt que dans la configuration décrite sur cette page.

Le tableau suivant indique quelles opérations AWS Glue courantes prennent en charge l'option de format ORC.

Lecture	Écrire	Lecture en streaming	Groupement des petits fichiers	Signets de tâche
Pris en charge	Pris en charge	Pris en charge	Non pris en charge	Pris en charge [*]

* Supporté dans la version 1.0+ de AWS Glue

Exemple : lecture de fichiers ou de dossiers ORC à partir de S3

Prérequis : vous aurez besoin des chemins S3 (s3path) vers des fichiers ou dossiers ORC que vous souhaitez lire.

Configuration : dans vos options de fonction, spécifiez `format="orc"`. Dans vos `connection_options`, utilisez la clé `paths` pour spécifier votre `s3path`. Vous pouvez configurer la manière dont le lecteur interagit avec S3 dans les `connection_options`. Pour plus de détails, voir Types de connexion et options pour l'ETL dans AWS Glue : [the section called “Paramètres de connexion S3”](#).

Le script AWS Glue ETL suivant montre le processus de lecture de fichiers ou de dossiers ORC depuis S3 :

Python

Pour cet exemple, utilisez la méthode [create_dynamic_frame.from_options](#).

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://s3path"]},
    format="orc"
)
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read\
    .orc("s3://s3path")
```

Scala

Pour cet exemple, utilisez l'opération [getSourceWithFormat](#).

```
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.GlueContext
import org.apache.spark.sql.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType="s3",
      format="orc",
      options=JsonOptions("""{"paths": ["s3://s3path"]}""")
    ).getDynamicFrame()
  }
}
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
val dataFrame = spark.read
    .orc("s3://s3path")
```

Exemple : écriture de fichiers et dossiers ORC dans S3

Prérequis : Vous aurez besoin d'un initialisé DataFrame (`dataFrame`) ou DynamicFrame (`dynamicFrame`). Vous aurez également besoin de votre chemin de sortie S3, `s3path`.

Configuration : dans vos options de fonction, spécifiez `format="orc"`. Dans vos options de connexion, utilisez `pathstouche` à spécifier `s3path`. Vous pouvez modifier davantage la manière dont le scripteur interagit avec S3 dans les `connection_options`. Pour plus de détails, voir Options de format de données pour les entrées et sorties ETL dans AWS Glue : [the section called “Paramètres de connexion S3”](#). L'exemple de code suivant montre le processus :

Python

Pour cet exemple, utilisez la méthode [write_dynamic_frame.from_options](#).

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="s3",
    format="orc",
    connection_options={
        "path": "s3://s3path"
    }
)
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
df.write.orc("s3://s3path/")
```

Scala

Pour cet exemple, utilisez la méthode [getSinkWithFormat](#).

```
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    glueContext.getSinkWithFormat(
      connectionType="s3",
      options=JsonOptions("""{"path": "s3://s3path"}"""),
      format="orc"
    ).writeDynamicFrame(dynamicFrame)
  }
}
```

```
}
```

Vous pouvez également l'utiliser DataFrames dans un script (`pyspark.sql.DataFrame`).

```
df.write.orc("s3://s3path/")
```

Référence de configuration ORC

Il n'y a aucune valeur `format_options` pour `format="orc"`. Cependant, les options acceptées par le code SparkSQL sous-jacent peuvent lui être transmises au moyen du paramètre de carte `connection_options`.

Utilisation de frameworks de lacs de données avec des tâches AWS Glue ETL

Les frameworks de lacs de données open source simplifient le traitement incrémentiel des données pour les fichiers que vous stockez dans des lacs de données basés sur Amazon S3. AWS Glue La version 3.0 et les versions ultérieures prennent en charge les frameworks de lacs de données open source suivants :

- Apache Hudi
- Linux Foundation Delta Lake
- Apache Iceberg

Nous fournissons une prise en charge native de ces cadres afin de vous permettre de lire et écrire les données à stocker dans Amazon S3 de manière cohérente sur le plan transactionnel. Il n'est pas nécessaire d'installer un connecteur distinct ou d'effectuer des étapes de configuration supplémentaires pour utiliser ces cadres dans les tâches AWS Glue ETL.

Lorsque vous gérez des ensembles de données via le AWS Glue Data Catalog, vous pouvez utiliser AWS Glue des méthodes pour lire et écrire des tables de lacs de données avec Spark DataFrames. Vous pouvez également lire et écrire des données Amazon S3 à l'aide de l' DataFrame API Spark.

Dans cette vidéo, vous découvrirez les principes de base du fonctionnement d'Apache Hudi, d'Apache Iceberg et de Delta Lake. Vous découvrirez comment insérer, mettre à jour et supprimer des données dans votre lac de données et comment chacun de ces cadres fonctionne.

Rubriques

- [Limites](#)

- [Utilisation du cadre Hudi dans AWS Glue](#)
- [Utilisation du framework Delta Lake dans AWS Glue](#)
- [Utilisation du cadre Iceberg dans AWS Glue](#)

Limites

Tenez compte des limites suivantes avant d'utiliser des frameworks de lacs de données avec AWS Glue.

- Les AWS Glue `GlueContext` méthodes suivantes `DynamicFrame` ne prennent pas en charge la lecture et l'écriture de tables du framework Data Lake. Utilisez plutôt les `GlueContext` méthodes pour `DataFrame` ou `DataFrame` l'API Spark.
 - `create_dynamic_frame.from_catalog`
 - `write_dynamic_frame.from_catalog`
 - `getDynamicFrame`
 - `writeDynamicFrame`
- Les `GlueContext` méthodes suivantes `DataFrame` sont prises en charge par le contrôle des autorisations de Lake Formation :
 - `create_data_frame.from_catalog`
 - `write_data_frame.from_catalog`
 - `getDataFrame`
 - `writeDataFrame`
- Le [regroupement de petits fichiers](#) n'est pas pris en charge.
- Les [signets de tâche](#) ne sont pas pris en charge.
- Apache Hudi 0.10.1 pour AWS Glue 3.0 ne prend pas en charge les tables Hudi Merge on Read (MoR).
- `ALTER TABLE ... RENAME TO` n'est pas disponible pour Apache Iceberg 0.13.1 pour 3.0. AWS Glue

Limitations des tables au format de lac de données gérées par les autorisations de Lake Formation

Les formats de lac de données sont intégrés à l'AWS Glue ETL via les autorisations Lake Formation. La création d'un `DynamicFrame` utilisateur `ncreate_dynamic_frame` est pas prise en charge. Pour plus d'informations, consultez les exemples suivants :

- [Exemple : lecture et écriture d'une table Iceberg avec contrôle des autorisations de Lake Formation](#)
- [Exemple : lecture et écriture d'une table Hudi avec contrôle des autorisations de Lake Formation](#)
- [Exemple : lecture et écriture d'une table Delta Lake avec contrôle des autorisations de Lake Formation](#)

 Note

L'intégration avec les autorisations AWS Glue ETL via Lake Formation pour Apache Hudi, Apache Iceberg et Delta Lake n'est prise en charge que dans la AWS Glue version 4.0.

Apache Iceberg offre la meilleure intégration avec l' AWS Glue ETL via les autorisations Lake Formation. Il prend en charge presque toutes les opérations et inclut la prise en charge de SQL.

Hudi prend en charge la plupart des opérations de base à l'exception des opérations administratives. C'est parce que ces options sont généralement effectuées via l'écriture de dataframes et spécifiées via `additional_options`. Vous devez l'utiliser pour créer AWS Glue APIs DataFrames pour vos opérations car SparkSQL n'est pas supporté.

Delta Lake prend uniquement en charge la lecture, l'ajout et le remplacement de données de table. Delta Lake nécessite l'utilisation de ses propres bibliothèques pour pouvoir effectuer diverses tâches telles que les mises à jour.

Les fonctionnalités suivantes ne sont pas disponibles pour les tables Iceberg gérées par les autorisations de Lake Formation.

- Compaction à l'aide AWS Glue de l'ETL
- Support de Spark SQL via AWS Glue ETL

Les limites des tables Hudi gérées par les autorisations de Lake Formation sont les suivantes :

- Suppression de fichiers orphelins

Les limites des tables Delta Lake gérées par les autorisations de Lake Formation sont les suivantes :

- Toutes les fonctionnalités autres que l'insertion et la lecture à partir des tables de Delta Lake.

Utilisation du cadre Hudi dans AWS Glue

AWS Glue 3.0 et versions ultérieures prennent en charge le framework Apache Hudi pour les lacs de données. Hudi est un cadre de stockage de lac de données open source qui simplifie le traitement incrémentiel des données et le développement de pipelines de données. Cette rubrique décrit les fonctionnalités disponibles pour utiliser vos données dans AWS Glue lorsque vous transportez ou stockez vos données dans une table Hudi. Pour en savoir plus sur Hudi, consultez la [documentation officielle d'Apache Hudi](#).

Vous pouvez utiliser AWS Glue pour effectuer des opérations de lecture et d'écriture sur des tables Hudi dans Amazon S3, ou travailler avec des tables Hudi à l'aide du catalogue de données AWS Glue. Des opérations supplémentaires, notamment l'insertion, la mise à jour et toutes les [opérations d'Apache Spark](#), sont également prises en charge.

Note

[L'implémentation d'Apache Hudi 0.15.0 dans AWS Glue 5.0 rétablit en interne le HUDI-7001.](#)

Il ne présente pas la régression liée à la génération de clés complexes lorsque la clé d'enregistrement est constituée d'un seul champ. Toutefois, ce comportement est différent de celui d'OSS Apache Hudi 0.15.0.

Apache Hudi 0.10.1 pour AWS Glue 3.0 ne prend pas en charge les tables Hudi Merge on Read (MoR).

Le tableau suivant répertorie la version Hudi incluse dans chaque version de AWS Glue.

AWS Version Glue	Version de Hudi prise en charge
5.0	0,15,0
4.0	0.12.1
3.0	0,1,1

Pour en savoir plus sur les frameworks de lacs de données pris en charge par AWS Glue, consultez [Utilisation de frameworks de lacs de données avec des tâches AWS Glue ETL](#).

Activation de Hudi

Pour activer Hudi for AWS Glue, effectuez les tâches suivantes :

- Spécifiez `hudi` comme valeur pour le paramètre de tâche `--datalake-formats`. Pour de plus amples informations, veuillez consulter [Utilisation des paramètres des tâches dans les tâches AWS Glue](#).
- Créez une clé nommée `--conf` d'après votre tâche AWS Glue et définissez-la sur la valeur suivante. Vous pouvez également définir la configuration suivante à l'aide de `SparkConf` dans votre script. Ces paramètres permettent à Apache Spark de gérer correctement les tables Hudi.

```
spark.serializer=org.apache.spark.serializer.KryoSerializer
```

- La prise en charge des autorisations de Lake Formation pour Hudi est activée par défaut pour AWS Glue 4.0. Aucune configuration supplémentaire n'est nécessaire pour la lecture/écriture dans les tables Hudi enregistrées dans Lake Formation. Pour lire une table Hudi enregistrée, le rôle IAM de la tâche AWS Glue doit disposer de l'autorisation `SELECT`. Pour écrire dans une table Hudi enregistrée, le rôle IAM de la tâche AWS Glue doit disposer de l'autorisation `SUPER`. Pour en savoir plus sur la gestion des autorisations de Lake Formation, consultez la section [Octroi et révocation d'autorisations liées aux ressources du catalogue de données](#).

Utilisation d'une autre version de Hudi

Pour utiliser une version de Hudi non prise en charge par AWS Glue, spécifiez vos propres fichiers JAR Hudi à l'aide du paramètre `--extra-jars job`. N'incluez pas `hudi` comme valeur du paramètre de tâche `--datalake-formats`. Si vous utilisez AWS Glue 5.0, vous devez définir le paramètre de `--user-jars-first true` tâche.

Exemple : écrire une table Hudi sur Amazon S3 et l'enregistrer dans le catalogue de données AWS Glue

Cet exemple de script montre comment écrire une table Hudi sur Amazon S3 et enregistrer la table dans le catalogue de données AWS Glue. L'exemple utilise l'[outil de synchronisation Hive](#) de Hudi pour enregistrer la table.

Note

Dans cet exemple, vous devez définir le paramètre `--enable-glue-datacatalog job` afin d'utiliser le catalogue de données AWS Glue comme métastore Apache Spark Hive. Pour

en savoir plus, veuillez consulter la section [Utilisation des paramètres des tâches dans les tâches AWS Glue](#).

Python

```
# Example: Create a Hudi table from a DataFrame
# and register the table to Glue Data Catalog

additional_options={
    "hoodie.table.name": "<your_table_name>",
    "hoodie.database.name": "<your_database_name>",
    "hoodie.datasource.write.storage.type": "COPY_ON_WRITE",
    "hoodie.datasource.write.operation": "upsert",
    "hoodie.datasource.write.recordkey.field": "<your_recordkey_field>",
    "hoodie.datasource.write.precombine.field": "<your_precombine_field>",
    "hoodie.datasource.write.partitionpath.field": "<your_partitionkey_field>",
    "hoodie.datasource.write.hive_style_partitioning": "true",
    "hoodie.datasource.hive_sync.enable": "true",
    "hoodie.datasource.hive_sync.database": "<your_database_name>",
    "hoodie.datasource.hive_sync.table": "<your_table_name>",
    "hoodie.datasource.hive_sync.partition_fields": "<your_partitionkey_field>",
    "hoodie.datasource.hive_sync.partition_extractor_class":
    "org.apache.hudi.hive.MultiPartKeysValueExtractor",
    "hoodie.datasource.hive_sync.use_jdbc": "false",
    "hoodie.datasource.hive_sync.mode": "hms",
    "path": "s3://<s3Path/>"
}

dataFrame.write.format("hudi") \
    .options(**additional_options) \
    .mode("overwrite") \
    .save()
```

Scala

```
// Example: Example: Create a Hudi table from a DataFrame
// and register the table to Glue Data Catalog

val additionalOptions = Map(
    "hoodie.table.name" -> "<your_table_name>",
    "hoodie.database.name" -> "<your_database_name>",
```

```

"hoodie.datasource.write.storage.type" -> "COPY_ON_WRITE",
"hoodie.datasource.write.operation" -> "upsert",
"hoodie.datasource.write.recordkey.field" -> "<your_recordkey_field>",
"hoodie.datasource.write.precombine.field" -> "<your_precombine_field>",
"hoodie.datasource.write.partitionpath.field" -> "<your_partitionkey_field>",
"hoodie.datasource.write.hive_style_partitioning" -> "true",
"hoodie.datasource.hive_sync.enable" -> "true",
"hoodie.datasource.hive_sync.database" -> "<your_database_name>",
"hoodie.datasource.hive_sync.table" -> "<your_table_name>",
"hoodie.datasource.hive_sync.partition_fields" -> "<your_partitionkey_field>",
"hoodie.datasource.hive_sync.partition_extractor_class" ->
"org.apache.hudi.hive.MultiPartKeysValueExtractor",
"hoodie.datasource.hive_sync.use_jdbc" -> "false",
"hoodie.datasource.hive_sync.mode" -> "hms",
"path" -> "s3://<s3Path/>")

dataFrame.write.format("hudi")
  .options(additionalOptions)
  .mode("append")
  .save()

```

Exemple : lecture d'une table Hudi depuis Amazon S3 à l'aide du catalogue de données AWS Glue

Cet exemple lit la table Hudi que vous avez créée dans [Exemple : écrire une table Hudi sur Amazon S3 et l'enregistrer dans le catalogue de données AWS Glue](#) depuis Amazon S3.

Note

Dans cet exemple, vous devez définir le paramètre `--enable-glue-datacatalog` job afin d'utiliser le catalogue de données AWS Glue comme métastore Apache Spark Hive. Pour en savoir plus, veuillez consulter la section [Utilisation des paramètres des tâches dans les tâches AWS Glue](#).

Python

Pour cet exemple, utilisez la méthode [GlueContext.create_data_frame_from_catalog\(\)](#).

```
# Example: Read a Hudi table from Glue Data Catalog
```

```

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

dataFrame = glueContext.create_data_frame.from_catalog(
    database = "<your_database_name>",
    table_name = "<your_table_name>"
)

```

Scala

Pour cet exemple, utilisez la méthode [getCatalogSource](#).

```

// Example: Read a Hudi table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    val dataFrame = glueContext.getCatalogSource(
      database = "<your_database_name>",
      tableName = "<your_table_name>"
    ).getDataFrame()
  }
}

```

Exemple : mise à jour et insertion d'un **DataFrame** dans une table Hudi d'Amazon S3

Cet exemple utilise le catalogue de données AWS Glue pour DataFrame insérer un dans la table Hudi que vous avez créée dans [Exemple : écrire une table Hudi sur Amazon S3 et l'enregistrer dans le catalogue de données AWS Glue](#).

Note

Dans cet exemple, vous devez définir le paramètre `--enable-glue-datacatalog job` afin d'utiliser le catalogue de données AWS Glue comme métastore Apache Spark Hive. Pour

en savoir plus, veuillez consulter la section [Utilisation des paramètres des tâches dans les tâches AWS Glue](#).

Python

Pour cet exemple, utilisez la méthode [GlueContext.write_data_frame.from_catalog\(\)](#).

```
# Example: Upsert a Hudi table from Glue Data Catalog

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

glueContext.write_data_frame.from_catalog(
    frame = dataFrame,
    database = "<your_database_name>",
    table_name = "<your_table_name>",
    additional_options={
        "hoodie.table.name": "<your_table_name>",
        "hoodie.database.name": "<your_database_name>",
        "hoodie.datasource.write.storage.type": "COPY_ON_WRITE",
        "hoodie.datasource.write.operation": "upsert",
        "hoodie.datasource.write.recordkey.field": "<your_recordkey_field>",
        "hoodie.datasource.write.precombine.field": "<your_precombine_field>",
        "hoodie.datasource.write.partitionpath.field": "<your_partitionkey_field>",
        "hoodie.datasource.write.hive_style_partitioning": "true",
        "hoodie.datasource.hive_sync.enable": "true",
        "hoodie.datasource.hive_sync.database": "<your_database_name>",
        "hoodie.datasource.hive_sync.table": "<your_table_name>",
        "hoodie.datasource.hive_sync.partition_fields": "<your_partitionkey_field>",
        "hoodie.datasource.hive_sync.partition_extractor_class":
            "org.apache.hudi.hive.MultiPartKeysValueExtractor",
        "hoodie.datasource.hive_sync.use_jdbc": "false",
        "hoodie.datasource.hive_sync.mode": "hms"
    }
)
```

Scala

Pour cet exemple, utilisez la méthode [getCatalogSink](#).


```
// Example: Upsert a Hudi table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    glueContext.getCatalogSink("<your_database_name>", "<your_table_name>",
      additionalOptions = JsonOptions(Map(
        "hoodie.table.name" -> "<your_table_name>",
        "hoodie.database.name" -> "<your_database_name>",
        "hoodie.datasource.write.storage.type" -> "COPY_ON_WRITE",
        "hoodie.datasource.write.operation" -> "upsert",
        "hoodie.datasource.write.recordkey.field" -> "<your_recordkey_field>",
        "hoodie.datasource.write.precombine.field" -> "<your_precombine_field>",
        "hoodie.datasource.write.partitionpath.field" ->
"<your_partitionkey_field>",
        "hoodie.datasource.write.hive_style_partitioning" -> "true",
        "hoodie.datasource.hive_sync.enable" -> "true",
        "hoodie.datasource.hive_sync.database" -> "<your_database_name>",
        "hoodie.datasource.hive_sync.table" -> "<your_table_name>",
        "hoodie.datasource.hive_sync.partition_fields" ->
"<your_partitionkey_field>",
        "hoodie.datasource.hive_sync.partition_extractor_class" ->
"org.apache.hudi.hive.MultiPartKeyValueExtractor",
        "hoodie.datasource.hive_sync.use_jdbc" -> "false",
        "hoodie.datasource.hive_sync.mode" -> "hms"
      )))
    .writeDataFrame(dataFrame, glueContext)
  }
}
```

Exemple : lecture d'une table Hudi depuis Amazon S3 à l'aide de Spark

Cet exemple lit une table Hudi depuis Amazon S3 à l'aide de l' API DataFrameAPI Spark.

Python

```
# Example: Read a Hudi table from S3 using a Spark DataFrame
```

```
dataFrame = spark.read.format("hudi").load("s3://<s3path/>")
```

Scala

```
// Example: Read a Hudi table from S3 using a Spark DataFrame  
  
val dataFrame = spark.read.format("hudi").load("s3://<s3path/>")
```

Exemple : écriture d'une table Hudi sur Amazon S3 à l'aide de Spark

Cet exemple écrit une table Hudi sur Amazon S3 à l'aide de Spark.

Python

```
# Example: Write a Hudi table to S3 using a Spark DataFrame  
  
dataFrame.write.format("hudi") \  
    .options(**additional_options) \  
    .mode("overwrite") \  
    .save("s3://<s3Path/>")
```

Scala

```
// Example: Write a Hudi table to S3 using a Spark DataFrame  
  
dataFrame.write.format("hudi")  
    .options(additionalOptions)  
    .mode("overwrite")  
    .save("s3://<s3path/>")
```

Exemple : lecture et écriture d'une table Hudi avec contrôle des autorisations de Lake Formation

Cet exemple lit et écrit dans une table Hudi avec contrôle des autorisations de Lake Formation.

1. Créez une table Hudi et enregistrez-la dans Lake Formation.

- a. Pour activer le contrôle des autorisations de Lake Formation, vous devez d'abord enregistrer le chemin d'accès Amazon S3 de la table sur Lake Formation. Pour plus d'informations, consultez la rubrique [Enregistrement d'un emplacement Amazon S3](#). Vous pouvez l'enregistrer depuis la console Lake Formation ou à l'aide de la AWS CLI :

```
aws lakeformation register-resource --resource-arn arn:aws:s3:::<s3-bucket>/<s3-
folder> --use-service-linked-role --region <REGION>
```

Une fois que vous avez enregistré un emplacement Amazon S3, toute table AWS Glue pointant vers cet emplacement (ou l'un de ses emplacements enfants) renverra la valeur du `IsRegisteredWithLakeFormation` paramètre comme vraie lors de l'`GetTable` appel.

- b. Créez une table Hudi qui pointe vers le chemin Amazon S3 enregistré via l'API Spark dataframe :

```
hudi_options = {
    'hoodie.table.name': table_name,
    'hoodie.database.name': database_name,
    'hoodie.datasource.write.storage.type': 'COPY_ON_WRITE',
    'hoodie.datasource.write.recordkey.field': 'product_id',
    'hoodie.datasource.write.table.name': table_name,
    'hoodie.datasource.write.operation': 'upsert',
    'hoodie.datasource.write.precombine.field': 'updated_at',
    'hoodie.datasource.write.hive_style_partitioning': 'true',
    'hoodie.upsert.shuffle.parallelism': 2,
    'hoodie.insert.shuffle.parallelism': 2,
    'path': <S3_TABLE_LOCATION>,
    'hoodie.datasource.hive_sync.enable': 'true',
    'hoodie.datasource.hive_sync.database': database_name,
    'hoodie.datasource.hive_sync.table': table_name,
    'hoodie.datasource.hive_sync.use_jdbc': 'false',
    'hoodie.datasource.hive_sync.mode': 'hms'
}

df_products.write.format("hudi") \
    .options(**hudi_options) \
    .mode("overwrite") \
    .save()
```

2. Accordez à Lake Formation l'autorisation d'accéder au rôle IAM AWS Glue Job. Vous pouvez accorder des autorisations à partir de la console Lake Formation ou à l'aide de la AWS CLI. Pour plus d'informations, consultez la rubrique [Octroi d'autorisations de table via la console Lake Formation et la méthode de ressource nommée](#)

3. Lisez la table Hudi enregistrée dans Lake Formation. Le code est le même que celui de la lecture d'une table Hudi non enregistrée. Notez que le rôle IAM de la tâche AWS Glue doit disposer de l'autorisation SELECT pour que la lecture réussisse.

```
val dataframe = glueContext.getCatalogSource(
    database = "<your_database_name>",
    tableName = "<your_table_name>"
).getDataFrame()
```

4. Écrire dans une table Hudi enregistrée dans Lake Formation. Le code est le même que celui de l'écriture dans une table Hudi non enregistrée. Notez que le rôle IAM de la tâche AWS Glue doit disposer de l'autorisation SUPER pour que l'écriture réussisse.

```
glueContext.getCatalogSink("<your_database_name>", "<your_table_name>",
    additionalOptions = JsonOptions(Map(
        "hoodie.table.name" -> "<your_table_name>",
        "hoodie.database.name" -> "<your_database_name>",
        "hoodie.datasource.write.storage.type" -> "COPY_ON_WRITE",
        "hoodie.datasource.write.operation" -> "<write_operation>",
        "hoodie.datasource.write.recordkey.field" -> "<your_recordkey_field>",
        "hoodie.datasource.write.precombine.field" -> "<your_precombine_field>",
        "hoodie.datasource.write.partitionpath.field" -> "<your_partitionkey_field>",
        "hoodie.datasource.write.hive_style_partitioning" -> "true",
        "hoodie.datasource.hive_sync.enable" -> "true",
        "hoodie.datasource.hive_sync.database" -> "<your_database_name>",
        "hoodie.datasource.hive_sync.table" -> "<your_table_name>",
        "hoodie.datasource.hive_sync.partition_fields" ->
"<your_partitionkey_field>",
        "hoodie.datasource.hive_sync.partition_extractor_class" ->
"org.apache.hudi.hive.MultiPartKeyValueExtractor",
        "hoodie.datasource.hive_sync.use_jdbc" -> "false",
        "hoodie.datasource.hive_sync.mode" -> "hms"
    )))
.writeDataFrame(dataFrame, glueContext)
```

Utilisation du framework Delta Lake dans AWS Glue

AWS Glue 3.0 et versions ultérieures prennent en charge le framework Delta Lake de la Linux Foundation. Delta Lake est un cadre de stockage de lac de données open source qui vous permet d'effectuer des transactions ACID, d'adapter la gestion des métadonnées et d'unifier le streaming et le traitement des données par lots. Cette rubrique décrit les fonctionnalités disponibles pour utiliser

vos données dans AWS Glue lorsque vous transportez ou stockez vos données dans une table Delta Lake. Pour en savoir plus sur Delta Lake, consultez la [documentation officielle de Delta Lake](#).

Vous pouvez utiliser AWS Glue pour effectuer des opérations de lecture et d'écriture sur des tables Delta Lake dans Amazon S3, ou travailler avec des tables Delta Lake à l'aide du catalogue de données AWS Glue. Des opérations supplémentaires telles que l'insertion, la mise à jour et la [lecture et l'écriture de tables par lots](#) sont également prises en charge. Lorsque vous utilisez des tables Delta Lake, vous avez également la possibilité d'avoir recours à des méthodes de la bibliothèque Python de Delta Lake, telles que `DeltaTable.forPath`. Pour plus d'informations sur la bibliothèque Python de Delta Lake, consultez la documentation Python de Delta Lake.

Le tableau suivant répertorie les versions de Delta Lake incluses dans chaque version de AWS Glue.

AWS Version Glue	Version de Delta Lake prise en charge
5.0	3.3.0
4.0	2.1.0
3.0	1.0.0

Pour en savoir plus sur les frameworks de lacs de données pris en charge par AWS Glue, consultez [Utilisation de frameworks de lacs de données avec des tâches AWS Glue ETL](#).

Activer Delta Lake pour AWS Glue

Pour activer Delta Lake for AWS Glue, effectuez les tâches suivantes :

- Spécifiez `delta` comme valeur pour le paramètre de tâche `--datalake-formats`. Pour de plus amples informations, veuillez consulter [Utilisation des paramètres des tâches dans les tâches AWS Glue](#).
- Créez une clé nommée `--conf` d'après votre tâche AWS Glue et définissez-la sur la valeur suivante. Vous pouvez également définir la configuration suivante à l'aide de `SparkConf` dans votre script. Ces paramètres permettent à Apache Spark de gérer correctement les tables Delta Lake.

```
spark.sql.extensions=io.delta.sql.DeltaSparkSessionExtension --conf
spark.sql.catalog.spark_catalog=org.apache.spark.sql.delta.catalog.DeltaCatalog --
```

```
conf
spark.delta.logStore.class=org.apache.spark.sql.delta.storage.S3SingleDriverLogStore
```

- La prise en charge des autorisations Lake Formation pour les tables Delta est activée par défaut pour AWS Glue 4.0. Aucune configuration supplémentaire n'est nécessaire pour la lecture/écriture dans les tables Delta enregistrées dans Lake Formation. Pour lire une table Delta enregistrée, le rôle IAM de la tâche AWS Glue doit disposer de l'autorisation SELECT. Pour écrire dans une table Delta enregistrée, le rôle IAM de la tâche AWS Glue doit disposer de l'autorisation SUPER. Pour en savoir plus sur la gestion des autorisations de Lake Formation, consultez la section [Octroi et révocation d'autorisations liées aux ressources du catalogue de données](#).

Utilisation d'une autre version de Delta Lake

Pour utiliser une version de Delta Lake non prise en charge par AWS Glue, spécifiez vos propres fichiers JAR Delta Lake à l'aide du paramètre `--extra-jars job`. N'incluez pas `delta` comme valeur du paramètre de tâche `--datalake-formats`. Si vous utilisez AWS Glue 5.0, vous devez définir le paramètre de tâche `--user-jars-first true`. Dans cette situation, pour utiliser la bibliothèque Python de Delta Lake, vous devez spécifier les fichiers JAR de la bibliothèque à l'aide du paramètre de tâche `--extra-py-files`. La bibliothèque Python est fournie dans les fichiers JAR de Delta Lake.

Exemple : écrire une table Delta Lake sur Amazon S3 et l'enregistrer dans le catalogue de données AWS Glue

Le script AWS Glue ETL suivant montre comment écrire une table Delta Lake sur Amazon S3 et enregistrer la table dans le catalogue de données AWS Glue.

Python

```
# Example: Create a Delta Lake table from a DataFrame
# and register the table to Glue Data Catalog

additional_options = {
    "path": "s3://<s3Path>"
}
dataFrame.write \
    .format("delta") \
    .options(**additional_options) \
    .mode("append") \
    .partitionBy("<your_partitionkey_field>") \
```

```
.saveAsTable("<your_database_name>.<your_table_name>")
```

Scala

```
// Example: Example: Create a Delta Lake table from a DataFrame
// and register the table to Glue Data Catalog

val additional_options = Map(
  "path" -> "s3://<s3Path>"
)
dataFrame.write.format("delta")
  .options(additional_options)
  .mode("append")
  .partitionBy("<your_partitionkey_field>")
  .saveAsTable("<your_database_name>.<your_table_name>")
```

Exemple : lecture d'une table Delta Lake depuis Amazon S3 à l'aide du catalogue de données AWS Glue

Le script AWS Glue ETL suivant lit la table Delta Lake que vous avez créée dans [Exemple : écrire une table Delta Lake sur Amazon S3 et l'enregistrer dans le catalogue de données AWS Glue](#).

Python

Pour cet exemple, utilisez la méthode [create_data_frame_from_catalog](#).

```
# Example: Read a Delta Lake table from Glue Data Catalog

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

df = glueContext.create_data_frame_from_catalog(
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
)
```

Scala

Pour cet exemple, utilisez la méthode [getCatalogSource](#).

```
// Example: Read a Delta Lake table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val df = glueContext.getCatalogSource("<your_database_name>",
    "<your_table_name>",
      additionalOptions = additionalOptions)
      .getDataFrame()
  }
}
```

Exemple : insertion d'un **DataFrame** dans une table Delta Lake dans Amazon S3 à l'aide du catalogue de données AWS Glue

Cet exemple insère des données dans la table Delta Lake que vous avez créée dans [Exemple : écrire une table Delta Lake sur Amazon S3 et l'enregistrer dans le catalogue de données AWS Glue](#).

Note

Dans cet exemple, vous devez définir le paramètre `--enable-glue-datacatalog` job afin d'utiliser le catalogue de données AWS Glue comme métastore Apache Spark Hive. Pour en savoir plus, veuillez consulter la section [Utilisation des paramètres des tâches dans les tâches AWS Glue](#).

Python

Pour cet exemple, utilisez la méthode [write_data_frame_from_catalog](#).

```
# Example: Insert into a Delta Lake table in S3 using Glue Data Catalog
```



```

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

glueContext.write_data_frame.from_catalog(
    frame=dataFrame,
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
)

```

Scala

Pour cet exemple, utilisez la méthode [getCatalogSink](#).

```

// Example: Insert into a Delta Lake table in S3 using Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    glueContext.getCatalogSink("<your_database_name>", "<your_table_name>",
      additionalOptions = additionalOptions)
      .writeDataFrame(dataFrame, glueContext)
  }
}

```

Exemple : lecture d'une table Delta Lake depuis Amazon S3 à l'aide de l'API Spark

Cet exemple lit une table Delta Lake depuis Amazon S3 à l'aide de l'API Spark.

Python

```

# Example: Read a Delta Lake table from S3 using a Spark DataFrame

dataFrame = spark.read.format("delta").load("s3://<s3path/>")

```

Scala

```
// Example: Read a Delta Lake table from S3 using a Spark DataFrame

val dataframe = spark.read.format("delta").load("s3://<s3path/>")
```

Exemple : écriture d'une table Delta Lake sur Amazon S3 à l'aide de Spark

Cet exemple écrit une table Delta Lake sur Amazon S3 à l'aide de Spark.

Python

```
# Example: Write a Delta Lake table to S3 using a Spark DataFrame

dataframe.write.format("delta") \
    .options(**additional_options) \
    .mode("overwrite") \
    .partitionBy("<your_partitionkey_field>") \
    .save("s3://<s3Path>")
```

Scala

```
// Example: Write a Delta Lake table to S3 using a Spark DataFrame

dataframe.write.format("delta")
    .options(additionalOptions)
    .mode("overwrite")
    .partitionBy("<your_partitionkey_field>")
    .save("s3://<s3path/>")
```

Exemple : lecture et écriture d'une table Delta Lake avec contrôle des autorisations de Lake Formation

Cet exemple lit et écrit dans une table Delta Lake avec contrôle des autorisations de Lake Formation.

1. Créez une table Delta et enregistrez-la dans Lake Formation

- a. Pour activer le contrôle des autorisations de Lake Formation, vous devez d'abord enregistrer le chemin d'accès Amazon S3 de la table sur Lake Formation. Pour plus d'informations, consultez la rubrique [Enregistrement d'un emplacement Amazon S3](#). Vous pouvez l'enregistrer depuis la console Lake Formation ou à l'aide de la AWS CLI :

```
aws lakeformation register-resource --resource-arn arn:aws:s3:::<s3-bucket>/<s3-  
folder> --use-service-linked-role --region <REGION>
```

Une fois que vous avez enregistré un emplacement Amazon S3, toute table AWS Glue pointant vers cet emplacement (ou l'un de ses emplacements enfants) renverra la valeur du `IsRegisteredWithLakeFormation` paramètre comme vraie lors de l'`GetTable` appel.

- b. Créez une table Delta qui pointe vers le chemin Amazon S3 enregistré via Spark :



Note

Voici des exemples Python.

```
dataFrame.write \  
  .format("delta") \  
  .mode("overwrite") \  
  .partitionBy("<your_partitionkey_field>") \  
  .save("s3://<the_s3_path>")
```

Une fois les données écrites sur Amazon S3, utilisez le robot AWS Glue pour créer une nouvelle table de catalogue Delta. Pour plus d'informations, voir [Présentation du support de table natif de Delta Lake avec les robots AWS Glue](#).

Vous pouvez également créer le tableau manuellement via l'`CreateTableAPI` AWS Glue.

2. Accordez à Lake Formation l'autorisation d'accéder au rôle IAM AWS Glue Job. Vous pouvez accorder des autorisations depuis la console Lake Formation ou utiliser la AWS CLI. Pour plus d'informations, consultez la rubrique [Octroi d'autorisations de table via la console Lake Formation et la méthode de ressource nommée](#)
3. Lisez la table Delta enregistrée dans Lake Formation. Le code est le même que celui de la lecture d'une table Delta non enregistrée. Notez que le rôle IAM de la tâche AWS Glue doit disposer de l'autorisation `SELECT` pour que la lecture réussisse.

```
# Example: Read a Delta Lake table from Glue Data Catalog  
  
df = glueContext.create_data_frame.from_catalog(  
    database="<your_database_name>",  
    table_name="<your_table_name>",
```

```
additional_options=additional_options  
)
```

4. Écrire dans une table Delta enregistrée dans Lake Formation. Le code est le même que celui de l'écriture dans une table Delta non enregistrée. Notez que le rôle IAM de la tâche AWS Glue doit disposer de l'autorisation SUPER pour que l'écriture réussisse.

Par défaut, AWS Glue utilise Append le mode SaveMode. Vous pouvez le modifier en définissant l'option saveMode dans additional_options. Pour plus d'informations sur la prise en charge du mode SaveMode dans les tables Delta, consultez [Écrire dans une table](#).

```
glueContext.write_data_frame.from_catalog(  
    frame=dataFrame,  
    database="<your_database_name>",  
    table_name="<your_table_name>",  
    additional_options=additional_options  
)
```

Utilisation du cadre Iceberg dans AWS Glue

AWS Glue 3.0 et versions ultérieures prennent en charge le framework Apache Iceberg pour les lacs de données. Iceberg fournit un format de table hautement performant qui fonctionne exactement comme une table SQL. Cette rubrique décrit les fonctionnalités disponibles pour utiliser vos données dans AWS Glue lorsque vous transportez ou stockez vos données dans une table Iceberg. Pour en savoir plus sur Iceberg, consultez la [documentation officielle d'Apache Iceberg](#).

Vous pouvez utiliser AWS Glue pour effectuer des opérations de lecture et d'écriture sur des tables Iceberg dans Amazon S3, ou travailler avec des tables Iceberg à l'aide du catalogue de données AWS Glue. Des opérations supplémentaires, notamment l'insertion et toutes les [requêtes Spark Writes](#) par [Spark](#), sont également prises en charge. La mise à jour n'est pas prise en charge pour les tables Iceberg.

Note

ALTER TABLE ... RENAME TO n'est pas disponible pour Apache Iceberg 0.13.1 pour AWS Glue 3.0.

Le tableau suivant répertorie les versions d'Iceberg incluses dans chaque version de AWS Glue.

AWS Version Glue	Version d'Iceberg prise en charge
5.0	1.7.1
4.0	1.0.0
3.0	0.13.1

Pour en savoir plus sur les frameworks de lacs de données pris en charge par AWS Glue, consultez [Utilisation de frameworks de lacs de données avec des tâches AWS Glue ETL](#).

Activation du cadre Iceberg

Pour activer Iceberg for AWS Glue, effectuez les tâches suivantes :

- Spécifiez `iceberg` comme valeur pour le paramètre de tâche `--datalake-formats`. Pour de plus amples informations, veuillez consulter [Utilisation des paramètres des tâches dans les tâches AWS Glue](#).
- Créez une clé nommée `--conf` d'après votre tâche AWS Glue et définissez-la sur la valeur suivante. Vous pouvez également définir la configuration suivante à l'aide de `SparkConf` dans votre script. Ces paramètres permettent à Apache Spark de gérer correctement les tables Iceberg.

```
spark.sql.extensions=org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions
--conf spark.sql.catalog.glue_catalog=org.apache.iceberg.spark.SparkCatalog
--conf spark.sql.catalog.glue_catalog.warehouse=s3://<your-warehouse-dir>/
--conf spark.sql.catalog.glue_catalog.catalog-impl=org.apache.iceberg.aws.glue.GlueCatalog
--conf spark.sql.catalog.glue_catalog.io-impl=org.apache.iceberg.aws.s3.S3FileIO
```

Si vous lisez ou écrivez sur des tables Iceberg enregistrées auprès de Lake Formation, suivez les instructions de AWS Glue 5.0 et versions ultérieures. [the section called “Lake Formation pour le FGAC”](#) Dans AWS Glue 4.0, ajoutez la configuration suivante pour activer le support de Lake Formation.

```
--conf spark.sql.catalog.glue_catalog.glue.lakeformation-enabled=true
--conf spark.sql.catalog.glue_catalog.glue.id=<table-catalog-id>
```

Si vous utilisez AWS Glue 3.0 avec Iceberg 0.13.1, vous devez définir les configurations supplémentaires suivantes pour utiliser le gestionnaire de verrouillage Amazon DynamoDB afin de garantir une transaction atomique. AWS Glue 4.0 ou version ultérieure utilise le verrouillage optimiste par défaut. Pour plus d'informations, consultez [Iceberg AWS Integrations](#) dans la documentation officielle d'Apache Iceberg.

```
--conf spark.sql.catalog.glue_catalog.lock-  
impl=org.apache.iceberg.aws.glue.DynamoLockManager  
--conf spark.sql.catalog.glue_catalog.lock.table=<your-dynamodb-table-name>
```

Utilisation d'une autre version d'Iceberg

Pour utiliser une version d'Iceberg non prise en charge par AWS Glue, spécifiez vos propres fichiers JAR Iceberg à l'aide du paramètre `--extra-jars job`. N'incluez pas `iceberg` comme valeur du paramètre `--datalake-formats`. Si vous utilisez AWS Glue 5.0, vous devez définir le paramètre de `--user-jars-first true` tâche.

Activation du chiffrement pour les tables Iceberg

Note

Les tables Iceberg possèdent leurs propres mécanismes pour activer le chiffrement côté serveur. Vous devez activer cette configuration en plus de la configuration de sécurité de AWS Glue.

Pour activer le chiffrement côté serveur sur les tables Iceberg, consultez les conseils de la [documentation d'Iceberg](#).

Ajouter une configuration Spark pour les différentes régions d'Iceberg

Pour ajouter une configuration Spark supplémentaire pour l'accès aux tables interrégionales d'Iceberg avec le AWS Glue Data Catalog AWS Lake Formation, suivez les étapes ci-dessous :

1. Créez un [point d'accès multirégional](#).
2. Définissez les propriétés Spark suivantes :

```
-----
```

```
--conf spark.sql.catalog.my_catalog.s3.use-arn-region-enabled=true \
--conf spark.sql.catalog.{CATALOG}.s3.access-points.bucket1",
"arn:aws:s3::<account-id>:accesspoint/<mrp-id>.mrp \
--conf spark.sql.catalog.{CATALOG}.s3.access-points.bucket2",
"arn:aws:s3::<account-id>:accesspoint/<mrp-id>.mrp
-----
```

Exemple : écrire une table Iceberg sur Amazon S3 et l'enregistrer dans le catalogue de données AWS Glue

Cet exemple de script montre comment écrire dans une table Iceberg dans Amazon S3. L'exemple utilise [Iceberg AWS Integrations](#) pour enregistrer la table dans le catalogue de données AWS Glue.

Python

```
# Example: Create an Iceberg table from a DataFrame
# and register the table to Glue Data Catalog

dataFrame.createOrReplaceTempView("tmp_<your_table_name>")

query = f"""
CREATE TABLE glue_catalog.<your_database_name>.<your_table_name>
USING iceberg
TBLPROPERTIES ("format-version"="2")
AS SELECT * FROM tmp_<your_table_name>
"""
spark.sql(query)
```

Scala

```
// Example: Example: Create an Iceberg table from a DataFrame
// and register the table to Glue Data Catalog

dataFrame.createOrReplaceTempView("tmp_<your_table_name>")

val query = """CREATE TABLE glue_catalog.<your_database_name>.<your_table_name>
USING iceberg
TBLPROPERTIES ("format-version"="2")
AS SELECT * FROM tmp_<your_table_name>
"""
spark.sql(query)
```

Vous pouvez également écrire dans une table Iceberg sur Amazon S3 et dans le catalogue de données à l'aide des méthodes Spark.

Conditions préalables : vous devez créer un catalogue pour que la bibliothèque Iceberg puisse l'utiliser. Lorsque vous utilisez le AWS catalogue de données AWS Glue, Glue simplifie les choses. Le catalogue de données AWS Glue est préconfiguré pour être utilisé par les bibliothèques Spark en tant que `glue_catalog`. Les tables du catalogue de données sont identifiées par `databaseName` et `tableName`. Pour plus d'informations sur le catalogue de données AWS Glue, consultez [Découverte et catalogage des données](#).

Si vous n'utilisez pas le catalogue de données AWS Glue, vous devrez approvisionner un catalogue via le Spark APIs. Pour plus d'informations, consultez [Spark Configuration](#) dans la documentation Iceberg.

Cet exemple écrit une table Iceberg dans Amazon S3 et le catalogue de données à l'aide de Spark.

Python

```
# Example: Write an Iceberg table to S3 on the Glue Data Catalog

# Create (equivalent to CREATE TABLE AS SELECT)
dataFrame.writeTo("glue_catalog.databaseName.tableName") \
    .tableProperty("format-version", "2") \
    .create()

# Append (equivalent to INSERT INTO)
dataFrame.writeTo("glue_catalog.databaseName.tableName") \
    .tableProperty("format-version", "2") \
    .append()
```

Scala

```
// Example: Write an Iceberg table to S3 on the Glue Data Catalog

// Create (equivalent to CREATE TABLE AS SELECT)
dataFrame.writeTo("glue_catalog.databaseName.tableName")
    .tableProperty("format-version", "2")
    .create()

// Append (equivalent to INSERT INTO)
dataFrame.writeTo("glue_catalog.databaseName.tableName")
    .tableProperty("format-version", "2")
```



```
.append()
```

Exemple : lecture d'une table Iceberg depuis Amazon S3 à l'aide du catalogue de données AWS Glue

Cet exemple lit la table Iceberg que vous avez créée dans [Exemple : écrire une table Iceberg sur Amazon S3 et l'enregistrer dans le catalogue de données AWS Glue](#).

Python

Pour cet exemple, utilisez la méthode

[`GlueContext.create\_data\_frame.from\_catalog\(\)`](#).

```
# Example: Read an Iceberg table from Glue Data Catalog

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

df = glueContext.create_data_frame.from_catalog(
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
)
```

Scala

Pour cet exemple, utilisez la méthode [`getCatalogSource`](#).

```
// Example: Read an Iceberg table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val df = glueContext.getCatalogSource("<your_database_name>",
    "<your_table_name>",
    additionalOptions = additionalOptions)
  }
}
```

```
        .getDataFrame()  
    }  
}
```

Exemple : insertion d'un **DataFrame** dans une table Iceberg dans Amazon S3 à l'aide du catalogue de données AWS Glue

Cet exemple insère des données dans la table Iceberg que vous avez créée dans [Exemple : écrire une table Iceberg sur Amazon S3 et l'enregistrer dans le catalogue de données AWS Glue](#).

Note

Dans cet exemple, vous devez définir le paramètre `--enable-glue-datacatalog job` afin d'utiliser le catalogue de données AWS Glue comme métastore Apache Spark Hive. Pour en savoir plus, veuillez consulter la section [Utilisation des paramètres des tâches dans les tâches AWS Glue](#).

Python

Pour cet exemple, utilisez la méthode [GlueContext.write_data_frame.from_catalog\(\)](#).

```
# Example: Insert into an Iceberg table from Glue Data Catalog  
  
from awsglue.context import GlueContext  
from pyspark.context import SparkContext  
  
sc = SparkContext()  
glueContext = GlueContext(sc)  
  
glueContext.write_data_frame.from_catalog(  
    frame=dataFrame,  
    database="<your_database_name>",  
    table_name="<your_table_name>",  
    additional_options=additional_options  
)
```

Scala

Pour cet exemple, utilisez la méthode [getCatalogSink](#).

```
// Example: Insert into an Iceberg table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    glueContext.getCatalogSink("<your_database_name>", "<your_table_name>",
      additionalOptions = additionalOptions)
      .writeDataFrame(dataFrame, glueContext)
  }
}
```

Exemple : lecture d'une table Iceberg depuis Amazon S3 à l'aide de Spark

Conditions préalables : vous devez créer un catalogue pour que la bibliothèque Iceberg puisse l'utiliser. Lorsque vous utilisez le AWS catalogue de données AWS Glue, Glue simplifie les choses. Le catalogue de données AWS Glue est préconfiguré pour être utilisé par les bibliothèques Spark en tant que `glue_catalog`. Les tables du catalogue de données sont identifiées par `databaseName` et `tableName`. Pour plus d'informations sur le catalogue de données AWS Glue, consultez [Découverte et catalogage des données](#).

Si vous n'utilisez pas le catalogue de données AWS Glue, vous devrez approvisionner un catalogue via le Spark APIs. Pour plus d'informations, consultez [Spark Configuration](#) dans la documentation Iceberg.

Cet exemple lit une table Iceberg dans Amazon S3 à partir du catalogue de données à l'aide de Spark.

Python

```
# Example: Read an Iceberg table on S3 as a DataFrame from the Glue Data Catalog

dataFrame = spark.read.format("iceberg").load("glue_catalog.<databaseName>.<tableName>")
```

Scala

```
// Example: Read an Iceberg table on S3 as a DataFrame from the Glue Data Catalog
```

```
val dataframe =  
  spark.read.format("iceberg").load("glue_catalog.databaseName.tableName")
```

Exemple : lecture et écriture d'une table Iceberg avec contrôle des autorisations de Lake Formation

Cet exemple lit et écrit dans une table Iceberg avec contrôle des autorisations de Lake Formation.

 Note

Cet exemple ne fonctionne que dans AWS Glue 4.0. Dans AWS Glue 5.0 et versions ultérieures, suivez les instructions de [the section called “Lake Formation pour le FGAC”](#).

1. Créez une table Iceberg et enregistrez-la dans Lake Formation :

- a. Pour activer le contrôle des autorisations de Lake Formation, vous devez d'abord enregistrer le chemin d'accès Amazon S3 de la table sur Lake Formation. Pour plus d'informations, consultez la rubrique [Enregistrement d'un emplacement Amazon S3](#). Vous pouvez l'enregistrer depuis la console Lake Formation ou à l'aide de la AWS CLI :

```
aws lakeformation register-resource --resource-arn arn:aws:s3:::<s3-bucket>/<s3-  
folder> --use-service-linked-role --region <REGION>
```

Une fois que vous avez enregistré un emplacement Amazon S3, toute table AWS Glue pointant vers cet emplacement (ou l'un de ses emplacements enfants) renverra la valeur du `IsRegisteredWithLakeFormation` paramètre comme vraie lors de l'appel `getTable`.

- b. Créez une table Iceberg qui pointe vers le chemin enregistré via Spark SQL :

 Note

Voici des exemples Python.

```
dataframe.createOrReplaceTempView("tmp_<your_table_name>")  
  
query = f"""  
CREATE TABLE glue_catalog.<your_database_name>.<your_table_name>  
USING iceberg
```

```
AS SELECT * FROM tmp_<your_table_name>
""
spark.sql(query)
```

Vous pouvez également créer le tableau manuellement via l'CreateTableAPI AWS Glue. Pour plus d'informations, consultez la section [Création de tables Apache Iceberg](#).

 Note

L'UpdateTableAPI ne prend actuellement pas en charge le format de table Iceberg en tant qu'entrée de l'opération.

2. Accordez à Lake Formation l'autorisation d'accéder au rôle IAM de la tâche. Vous pouvez accorder des autorisations depuis la console Lake Formation ou utiliser la AWS CLI. Pour plus d'informations, voir : <https://docs.aws.amazon.com/lake-formation/latest/dg/granting-table-permissions.html>
3. Lisez une table Iceberg enregistrée dans Lake Formation. Le code est le même que celui de la lecture d'une table Iceberg non enregistrée. Notez que le rôle IAM de votre job AWS Glue doit disposer de l'autorisation SELECT pour que la lecture réussisse.

```
# Example: Read an Iceberg table from the AWS Glue Data Catalog
from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

df = glueContext.create_data_frame.from_catalog(
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
)
```

4. Écrivez dans une table Iceberg enregistrée dans Lake Formation. Le code est le même que celui de l'écriture dans une table Iceberg non enregistrée. Notez que le rôle IAM de votre tâche AWS Glue doit disposer de l'autorisation SUPER pour que l'écriture réussisse.

```
glueContext.write_data_frame.from_catalog(
    frame=dataFrame,
    database="<your_database_name>",
    table_name="<your_table_name>",
```

```
additional_options=additional_options  
)
```

Référence de configuration partagée

Vous pouvez utiliser les valeurs `format_options` suivantes avec tout type de format.

- `attachFilename` : une chaîne au format approprié à utiliser comme nom de colonne. Si vous fournissez cette option, le nom du fichier source de l'enregistrement sera ajouté à l'enregistrement. La valeur du paramètre sera utilisée comme nom de colonne.
- `attachTimestamp` : une chaîne au format approprié à utiliser comme nom de colonne. Si vous fournissez cette option, l'heure de la modification du fichier source de l'enregistrement sera ajoutée à l'enregistrement. La valeur du paramètre sera utilisée comme nom de colonne.

AWS Support de Glue Data Catalog pour les tâches Spark SQL

Le catalogue de données AWS Glue est un catalogue compatible avec le métastore Apache Hive. Vous pouvez configurer votre AWS Glue jobs et points de terminaison de développement pour utiliser le catalogue de données en tant que métastore Apache Hive externe. Vous pouvez ensuite exécuter directement des requêtes SQL Apache Spark sur les tables stockées dans le catalogue de données. AWS Glue les cadres dynamiques s'intègrent au catalogue de données par défaut. Toutefois, avec cette fonctionnalité, les tâches Spark SQL peuvent commencer à utiliser Data Catalog en tant que métastore Hive externe.

Cette fonctionnalité nécessite un accès réseau au AWS Glue Point de terminaison d'API. Dans AWS Glue pour les tâches dont les connexions sont situées dans des sous-réseaux privés, vous devez configurer un point de terminaison VPC ou une passerelle NAT pour fournir l'accès au réseau. Pour plus d'informations sur la configuration des points de terminaison de VPC, reportez-vous à [Configuration de l'accès réseau aux magasins de données](#). Pour créer une passerelle NAT, veuillez consulter [Passerelles NAT](#) dans le Guide de l'utilisateur Amazon VPC.

Vous pouvez configurer AWS Glue tâches et points de terminaison de développement en ajoutant l'"--enable-glue-datacatalog": "" argument aux arguments de tâche et aux arguments de point de terminaison de développement respectivement. La transmission de cet argument définit certaines configurations dans Spark qui lui permettent d'accéder à Data Catalog en tant que métastore Hive externe. Il [permet également de prendre en charge Hive](#) dans l'`SparkSession` objet créé dans le AWS Glue point de terminaison d'emploi ou de développement.

Pour activer l'accès au catalogue de données, cochez la case Utiliser le catalogue de données AWS Glue comme métastore Hive dans le groupe d'options du catalogue sur la page Ajouter une tâche ou Ajouter un point de terminaison de la console. Notez que le rôle IAM utilisé pour la tâche ou le point de terminaison de développement doit disposer des autorisations `glue:CreateDatabase`. Une base de données appelée « `default` » est créée dans Data Catalog, si elle n'existe pas déjà.

Prenons l'exemple de la façon dont vous pouvez utiliser cette fonction dans vos tâches Spark SQL. L'exemple suivant suppose que vous avez analysé l'ensemble de données des législateurs américains disponible dans `s3://awsglue-datasets/examples/us-legislators`.

Pour sérialiser/désérialiser les données des tables définies dans le catalogue de données AWS Glue, Spark SQL a besoin de la SerDe classe [Hive](#) pour le format défini dans le catalogue de données AWS Glue dans le chemin de classe de la tâche Spark.

SerDes car certains formats courants sont distribués par AWS Glue. Les liens Amazon S3 correspondants sont les suivants :

- [JSON](#)
- [XML](#)
- [Grok](#)

Ajoutez le JSON SerDe en tant que [JAR supplémentaire au point de terminaison de développement](#). Pour les tâches, vous pouvez ajouter l'`--extra-jars` argument SerDe using the dans le champ des arguments. Pour de plus amples informations, veuillez consulter [Utilisation des paramètres des tâches dans les tâches AWS Glue](#).

Voici un exemple d'entrée JSON pour créer un point de terminaison de développement avec Data Catalog activé pour Spark SQL.

```
{
  "EndpointName": "Name",
  "RoleArn": "role_ARN",
  "PublicKey": "public_key_contents",
  "NumberOfNodes": 2,
  "Arguments": {
    "--enable-glue-datacatalog": ""
  },
  "ExtraJarsS3Path": "s3://crawler-public/json/serde/json-serde.jar"
```

```
}

```

Maintenant, interrogez les tables créées à partir de l'ensemble de données des législateurs américains à l'aide de Spark SQL.

```
>>> spark.sql("use legislators")
DataFrame[]
>>> spark.sql("show tables").show()
+-----+-----+-----+
| database|      tableName|isTemporary|
+-----+-----+-----+
|legislators|      areas_json|      false|
|legislators|  countries_json|      false|
|legislators|    events_json|      false|
|legislators|memberships_json|      false|
|legislators|organizations_json|      false|
|legislators|    persons_json|      false|
+-----+-----+-----+
>>> spark.sql("describe memberships_json").show()
+-----+-----+-----+
|      col_name|data_type|      comment|
+-----+-----+-----+
|      area_id|  string|from deserializer|
|on_behalf_of_id|  string|from deserializer|
|organization_id|  string|from deserializer|
|      role|  string|from deserializer|
|  person_id|  string|from deserializer|
|legislative_perio...|  string|from deserializer|
|      start_date|  string|from deserializer|
|      end_date|  string|from deserializer|
+-----+-----+-----+
```

Si la SerDe classe correspondant au format n'est pas disponible dans le chemin de classe de la tâche, une erreur semblable à la suivante s'affichera.

```
>>> spark.sql("describe memberships_json").show()

Caused by: MetaException(message:java.lang.ClassNotFoundException Class
org.openx.data.jsonserde.JsonSerDe not found)
    at
    org.apache.hadoop.hive.metastore.MetaStoreUtils.getDeserializer(MetaStoreUtils.java:399)
```



```
at
org.apache.hadoop.hive.ql.metadata.Table.getDeserializerFromMetaStore(Table.java:276)
... 64 more
```

Pour afficher uniquement les éléments `organization_id` distincts à partir de la table `memberships`, exécutez la requête SQL suivante.

```
>>> spark.sql("select distinct organization_id from memberships_json").show()
+-----+
| organization_id|
+-----+
|d56acebe-8fdc-47b...|
|8fa6c3d2-71dc-478...|
+-----+
```

Si vous devez faire de même avec des images dynamiques, exécutez le code suivant.

```
>>> memberships = glueContext.create_dynamic_frame.from_catalog(database="legislators",
    table_name="memberships_json")
>>> memberships.toDF().createOrReplaceTempView("memberships")
>>> spark.sql("select distinct organization_id from memberships").show()
+-----+
| organization_id|
+-----+
|d56acebe-8fdc-47b...|
|8fa6c3d2-71dc-478...|
+-----+
```

Bien qu' `DynamicFrames` ils soient optimisés pour les opérations ETL, le fait de permettre à Spark SQL d'accéder directement au catalogue de données fournit un moyen concis d'exécuter des instructions SQL complexes ou de porter des applications existantes.

Utilisation des marque-pages de tâche

AWS Glue for Spark utilise des signets de tâches pour suivre les données déjà traitées. Pour un résumé de la fonctionnalité des signets de tâches et de ce qu'elle prend en charge, consultez [the section called “Suivi des données traitées à l'aide de signets de tâche”](#). Lorsque vous programmez une AWS Glue tâche avec des signets, vous avez accès à une flexibilité qui n'est pas disponible dans les tâches visuelles.

- Lorsque vous lisez à partir de JDBC, vous pouvez spécifier la ou les colonnes à utiliser comme clés de signet dans votre script. AWS Glue
- Vous pouvez choisir la `transformation_ctx` à appliquer à chaque appel de méthode.

Appelez toujours `job.init` au début et `job.commit` à la fin du script avec les paramètres correctement configurés. Ces deux fonctions initialisent le service de signet et mettent à jour le changement d'état vers le service. Les marque-pages ne fonctionnent pas s'ils ne sont pas appelés.

Spécifier les clés des signets

Pour les flux de travail JDBC, le signet assure le suivi des lignes lues par votre tâche en comparant les valeurs des champs clés à la valeur d'un signet. Cela n'est ni nécessaire ni applicable aux flux de travail Amazon S3. Lorsque vous écrivez un AWS Glue script sans l'éditeur visuel, vous pouvez spécifier la colonne à suivre à l'aide de signets. Vous pouvez aussi spécifier plusieurs colonnes. Des écarts dans la séquence de valeurs sont autorisés lorsque vous spécifiez des clés de signet définies par l'utilisateur.

Warning

Si des clés de signets définies par l'utilisateur sont utilisées, elles doivent toutes croître ou diminuer de façon monotone. Lorsque vous sélectionnez des champs supplémentaires pour une clé composée, les champs correspondants à des concepts tels que les « versions mineures » ou « numéros de révision » ne répondent pas à ce critère, car leurs valeurs sont réutilisées dans l'ensemble de votre jeu de données.

Vous pouvez spécifier `jobBookmarkKeys` et `jobBookmarkKeysSortOrder` de la manière suivante :

- `create_dynamic_frame.from_catalog` – Utiliser `additional_options`.
- `create_dynamic_frame.from_options` – Utiliser `connection_options`.

Contexte de transformation

La plupart des AWS Glue PySpark les méthodes de trame dynamique incluent un paramètre facultatif nommé `transformation_ctx`, qui est un identifiant unique pour l'instance d'opérateur ETL. Le paramètre `transformation_ctx` permet d'identifier les informations d'état dans un marque-page

de tâche pour l'opérateur donné. Plus précisément, AWS Glue permet `transformation_ctx` d'indexer la clé sur l'état du signet.

Warning

Le paramètre `transformation_ctx` sert de clé pour rechercher dans l'état du marque-page une source spécifique dans votre script. Pour que le marque-page fonctionne correctement, vous devez toujours conserver la source et la cohérence du paramètre `transformation_ctx` associée. La modification de la propriété source ou le renommage du paramètre `transformation_ctx` peut rendre le marque-page précédent invalide et le filtrage basé sur l'horodatage peut ne pas donner le bon résultat.

Pour que les marque-pages de tâche fonctionnent correctement, activez le paramètre de signet de tâche et définissez le paramètre `transformation_ctx`. Si vous ne transmettez pas le paramètre `transformation_ctx`, les marque-pages de tâche ne sont pas activés pour une trame dynamique ou un tableau utilisé dans la méthode. Par exemple, si vous avez une tâche ETL qui lit et joint deux sources Amazon S3, vous pouvez choisir de transmettre le paramètre `transformation_ctx` uniquement aux méthodes qui doivent activer les marque-pages. Si vous réinitialisez le marque-page de tâche d'une tâche, toutes les transformations associées à cette tâche sont réinitialisées, quel que soit le paramètre `transformation_ctx` utilisé.

Pour plus d'informations sur la classe `DynamicFrameReader`, consultez [DynamicFrameReader classe](#). Pour plus d'informations sur les PySpark extensions, consultez [AWS Référence des PySpark extensions Glue](#).

Exemples

Exemple

Voici un exemple de script généré pour une source de données Amazon S3. Les parties du script nécessaires à l'utilisation des signets de tâche sont indiquées en italique. Pour plus d'informations sur ces éléments, consultez l'API [GlueContext classe](#) et l'API [DynamicFrameWriter classe](#).

```
# Sample Script
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
```

```

from awsglue.job import Job

args = getResolvedOptions(sys.argv, ['JOB_NAME'])
sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args['JOB_NAME'], args)

datasource0 = glueContext.create_dynamic_frame.from_catalog(
    database = "database",
    table_name = "relatedqueries_csv",
    transformation_ctx = "datasource0"
)

applymapping1 = ApplyMapping.apply(
    frame = datasource0,
    mappings = [("col0", "string", "name", "string"), ("col1", "string", "number",
"string")],
    transformation_ctx = "applymapping1"
)

datasink2 = glueContext.write_dynamic_frame.from_options(
    frame = applymapping1,
    connection_type = "s3",
    connection_options = {"path": "s3://input_path"},
    format = "json",
    transformation_ctx = "datasink2"
)

job.commit()

```

Example

Voici un exemple de script généré pour une source JDBC. La table source est une table d'employés avec la colonne empno comme clé principale. Bien que par défaut la tâche utilise une clé principale séquentielle comme clé de marque-page si aucune clé de marque-page n'est spécifiée, car empno n'est pas nécessairement séquentiel, il peut y avoir des lacunes dans les valeurs, elle n'est pas considérée comme une clé de marque-page par défaut. Par conséquent, le script désigne explicitement empno comme clé de marque-page. Cette partie du code est affichée en italique.

```
import sys
```

```
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args['JOB_NAME'], args)

datasource0 = glueContext.create_dynamic_frame.from_catalog(
    database = "hr",
    table_name = "emp",
    transformation_ctx = "datasource0",
    additional_options = {"jobBookmarkKeys":["empno"],"jobBookmarkKeysSortOrder":"asc"}
)

applymapping1 = ApplyMapping.apply(
    frame = datasource0,
    mappings = [("ename", "string", "ename", "string"), ("hrly_rate", "decimal(38,0)",
"hrly_rate", "decimal(38,0)"), ("comm", "decimal(7,2)", "comm", "decimal(7,2)"),
("hiredate", "timestamp", "hiredate", "timestamp"), ("empno", "decimal(5,0)", "empno",
"decimal(5,0)"), ("mgr", "decimal(5,0)", "mgr", "decimal(5,0)"), ("photo", "string",
"photo", "string"), ("job", "string", "job", "string"), ("deptno", "decimal(3,0)",
"deptno", "decimal(3,0)"), ("ssn", "decimal(9,0)", "ssn", "decimal(9,0)"), ("sal",
"decimal(7,2)", "sal", "decimal(7,2)"),],
    transformation_ctx = "applymapping1"
)

datasink2 = glueContext.write_dynamic_frame.from_options(
    frame = applymapping1,
    connection_type = "s3",
    connection_options = {"path": "s3://hr/employees"},
    format = "csv",
    transformation_ctx = "datasink2"
)

job.commit()
```

Utilisation de la détection des données sensibles en dehors de AWS Glue Studio

AWS Glue Studio vous permet de détecter les données sensibles, mais vous pouvez également utiliser la fonctionnalité de détection des données sensibles en dehors de AWS Glue Studio.

Pour afficher la liste complète des types de données sensibles gérés, consultez [Managed data types](#).

Détection de données sensibles Détection à l'aide de types d'informations personnelles AWS gérés

AWS Glue en fournit deux APIs dans une tâche AWS Glue ETL. `detect()` et `classifyColumns()` :

```
detect(frame: DynamicFrame,
      entityTypesToDetect: Seq[String],
      outputColumnName: String = "DetectedEntities",
      detectionSensitivity: String = "LOW"): DynamicFrame

detect(frame: DynamicFrame,
      detectionParameters: JsonOptions,
      outputColumnName: String = "DetectedEntities",
      detectionSensitivity: String = "LOW"): DynamicFrame

classifyColumns(frame: DynamicFrame,
      entityTypesToDetect: Seq[String],
      sampleFraction: Double = 0.1,
      thresholdFraction: Double = 0.1,
      detectionSensitivity: String = "LOW")
```

Vous pouvez utiliser l'`detect()` API pour identifier les types d' AWS informations personnelles gérées et les types d'entités personnalisés. Une nouvelle colonne est automatiquement créée avec le résultat de la détection. L'API `classifyColumns()` renvoie une carte où les clés sont les noms de colonnes et les valeurs sont la liste des types d'entités détectés. `SampleFraction` indique la fraction des données à échantillonner lors de la recherche d'entités PII, tandis que `ThresholdFraction` indique la fraction des données qui doit être satisfaite pour qu'une colonne soit identifiée comme données PII.

Détection au niveau des lignes

Dans l'exemple, la tâche exécute les actions suivantes à l'aide des touches `detect()` et `classifyColumns()` APIs :

- lire les données d'un Amazon S3 bucket et les transformer en DynamicFrame
- détection des instances « Email » et « Credit Card » dans le DynamicFrame
- renvoi d'un DynamicFrame avec les valeurs d'origine plus une colonne qui englobe le résultat de la détection pour chaque ligne
- écrire le DynamicFrame renvoyé dans un autre chemin Amazon S3

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._
import com.amazonaws.services.glue.ml.EntityDetector

object GlueApp {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
    val frame=
glueContext.getSourceWithFormat(formatOptions=JsonOptions("""{"quoteChar": "\"",
"withHeader": true, "separator": ","}"""), connectionType="s3", format="csv",
options=JsonOptions("""{"paths": ["s3://pathToSource"], "recurse": true}"""),
transformationContext="AmazonS3_node1650160158526").getDynamicFrame()

    val frameWithDetectedPII = EntityDetector.detect(frame, Seq("EMAIL",
"CREDIT_CARD"))

    glueContext.getSinkWithFormat(connectionType="s3",
options=JsonOptions("""{"path": "s3://pathToOutput/", "partitionKeys": []}"""),
transformationContext="someCtx",
format="json").writeDynamicFrame(frameWithDetectedPII)

    Job.commit()
  }
}
```

Détection au niveau des lignes avec actions détaillées

Dans l'exemple, la tâche exécute les actions suivantes à l'aide de `detect()` APIs :

- lecture des données à partir d'un compartiment Amazon S3 et transformation de ces données en `DynamicFrame`
- détection des types de données sensibles pour « USA_PTIN », « BANK_ACCOUNT », « USA_SSN », « USA_PASSPORT_NUMBER » et « PHONE_NUMBER » dans le `DynamicFrame`
- renvoi d'un `DynamicFrame` avec les valeurs modifiées masquées plus une colonne qui englobe le résultat de la détection pour chaque ligne
- écriture du `DynamicFrame` renvoyé dans un autre chemin Amazon S3

Contrairement à l'API `detect()` ci-dessus, celle-ci utilise des actions détaillées que les types d'entités détectent. Pour de plus amples informations, veuillez consulter [Paramètres de détection pour l'utilisation de `detect\(\)`](#).

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._
import com.amazonaws.services.glue.ml.EntityDetector

object GlueApp {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
    val frame =
      glueContext.getSourceWithFormat(formatOptions=JsonOptions("""{"quoteChar": "\"",
"withHeader": true, "separator": ","}"""), connectionType="s3", format="csv",
options=JsonOptions("""{"paths": ["s3://pathToSource"], "recurse": true}"""),
transformationContext="AmazonS3_node_source").getDynamicFrame()
```



```

val detectionParameters = JsonOptions(
  """
  {
    "USA_DRIVING_LICENSE": [{
      "action": "PARTIAL_REDACT",
      "sourceColumns": ["Driving License"],
      "actionOptions": {
        "matchPattern": "[0-9]",
        "redactChar": "*"
      }
    }],
    "BANK_ACCOUNT": [{
      "action": "DETECT",
      "sourceColumns": ["*"]
    }],
    "USA_SSN": [{
      "action": "SHA256_HASH",
      "sourceColumns": ["SSN"]
    }],
    "IP_ADDRESS": [{
      "action": "REDACT",
      "sourceColumns": ["IP Address"],
      "actionOptions": {"redactText": "*****"}
    }],
    "PHONE_NUMBER": [{
      "action": "PARTIAL_REDACT",
      "sourceColumns": ["Phone Number"],
      "actionOptions": {
        "numLeftCharsToExclude": 1,
        "numRightCharsToExclude": 0,
        "redactChar": "*"
      }
    }],
  }
  """
)

val frameWithDetectedPII = EntityDetector.detect(frame, detectionParameters,
"DetectedEntities", "HIGH")

glueContext.getSinkWithFormat(connectionType="s3", options=JsonOptions("""{"path":
"s3://pathToOutput/", "partitionKeys": []}"""),
transformationContext="AmazonS3_node_target",
format="json").writeDynamicFrame(frameWithDetectedPII)

```

```

        Job.commit()
    }
}

```

Détection au niveau des colonnes

Dans l'exemple, la tâche exécute les actions suivantes à l'aide de `classifyColumns()` APIs :

- lecture des données à partir d'un compartiment Amazon S3 et transformation de ces données en `DynamicFrame`
- détection des instances « Email » et « Credit Card » dans le `DynamicFrame`
- définir les paramètres pour échantillonner 100 % de la colonne, marquer une entité comme détectée si elle se trouve dans 10 % des cellules et a une sensibilité « FAIBLE »
- renvoie une carte où les clés sont les noms de colonnes et les valeurs sont une liste des types d'entités détectés
- écriture du `DynamicFrame` renvoyé dans un autre chemin Amazon S3

```

import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._
import com.amazonaws.services.glue.DynamicFrame
import com.amazonaws.services.glue.ml.EntityDetector

object GlueApp {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
    val frame =
      glueContext.getSourceWithFormat(formatOptions=JsonOptions("""{"quoteChar":
        "\"", "withHeader": true, "separator": ",", "optimizePerformance": false}"""),

```

```

connectionType="s3", format="csv", options=JsonOptions("""{"paths": ["s3://
pathToSource"], "recurse": true}"""), transformationContext="frame").getDynamicFrame()

import glueContext.sparkSession.implicits._

val detectedDataFrame = EntityDetector.classifyColumns(
    frame,
    entityTypeToDetect = Seq("CREDIT_CARD", "PHONE_NUMBER"),
    sampleFraction = 1.0,
    thresholdFraction = 0.1,
    detectionSensitivity = "LOW"
)
val detectedDF = (detectedDataFrame).toSeq.toDF("columnName", "entityTypes")
val DetectSensitiveData_node = DynamicFrame(detectedDF, glueContext)

glueContext.getSinkWithFormat(connectionType="s3", options=JsonOptions("""{"path":
"s3://pathToOutput", "partitionKeys": []}"""), transformationContext="someCtx",
format="json").writeDynamicFrame(DetectSensitiveData_node)

Job.commit()
}
}

```

Détection de données sensibles Détection à l'aide de AWS CustomEntityType types d'informations personnelles

Vous pouvez définir des entités personnalisées via AWS Studio. Toutefois, pour utiliser cette fonctionnalité en dehors de AWS Studio, vous devez d'abord définir les types d'entités personnalisés, puis ajouter les types d'entités personnalisés définis à la liste des `entityTypesToDetect`.

Si vos données contiennent des types de données sensibles spécifiques (tels que l'ID d'employé), vous pouvez créer des entités personnalisées en appelant l'API `CreateCustomEntityType()`. L'exemple suivant définit le type d'entité personnalisé « `EMPLOYEE_ID` » pour l'API `CreateCustomEntityType()` avec les paramètres de demande :

```

{
  "name": "EMPLOYEE_ID",
  "regexString": "\\d{4}-\\d{3}",
  "contextWords": ["employee"]
}

```

```
}
```

Modifiez ensuite la tâche pour utiliser le nouveau type de données sensibles personnalisé en ajoutant le type d'entité personnalisé (EMPLOYEE_ID) à l'API `EntityDetector()` :

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._
import com.amazonaws.services.glue.ml.EntityDetector

object GlueApp {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
    val frame=
glueContext.getSourceWithFormat(formatOptions=JsonOptions("""{"quoteChar": "\"",
"withHeader": true, "separator": ","}"""), connectionType="s3", format="csv",
options=JsonOptions("""{"paths": ["s3://pathToSource"], "recurse": true}"""),
transformationContext="AmazonS3_node1650160158526").getDynamicFrame()

    val frameWithDetectedPII = EntityDetector.detect(frame, Seq("EMAIL",
"CREDIT_CARD", "EMPLOYEE_ID"))

    glueContext.getSinkWithFormat(connectionType="s3",
options=JsonOptions("""{"path": "s3://pathToOutput/", "partitionKeys": []}"""),
transformationContext="someCtx",
format="json").writeDynamicFrame(frameWithDetectedPII)

    Job.commit()
  }
}
```

 Note

Si un type de données sensibles personnalisé est défini avec le même nom qu'un type d'entité géré existant, le type de données sensibles personnalisé prévaut et remplace la logique du type d'entité géré.

Paramètres de détection pour l'utilisation de **detect()**

Cette méthode est utilisée pour détecter des entités dans un `DynamicFrame`. Il renvoie une nouvelle colonne `DataFrame` contenant les valeurs d'origine et une colonne supplémentaire `outputColumnName` contenant des métadonnées de détection des informations personnelles. Un masquage personnalisé peut être effectué une fois `DynamicFrame` celui-ci renvoyé dans le AWS Glue un script ou l'API `detect()` avec des actions détaillées peuvent être utilisés à la place.

```
detect(frame: DynamicFrame,  
      entityTypeToDetect: Seq[String],  
      outputColumnName: String = "DetectedEntities",  
      detectionSensitivity: String = "LOW"): DynamicFrame
```

Paramètres :

- `frame` — (type : `DynamicFrame`) L'entrée `DynamicFrame` contenant les données à traiter.
- `entityTypesToDétecter` — (type : `[Seq[String]]`) Liste des types d'entités à détecter. Il peut s'agir de types d'entités gérés ou de types d'entités personnalisés.
- `outputColumnName` — (type : `String`, par défaut : `"DetectedEntities"`) Le nom de la colonne dans laquelle les entités détectées seront stockées. S'il n'est pas fourni, le nom de colonne par défaut est « `DetectedEntities` ».
- `detectionSensitivity` — (type : `String`, options : « `FAIBLE` » ou « `ÉLEVÉ` », par défaut : « `FAIBLE` ») spécifie la sensibilité du processus de détection. Les options valides sont « `FAIBLE` » ou « `ÉLEVÉ` ». Si ce n'est pas le cas, la sensibilité par défaut est réglée sur « `FAIBLE` ».

Paramètres `outputColumnName` :

Le nom de la colonne dans laquelle les entités détectées seront stockées. S'il n'est pas fourni, le nom de colonne par défaut est « `DetectedEntities` ». Pour chaque ligne de la colonne de sortie, la colonne

supplémentaire inclut un mappage du nom de la colonne avec les métadonnées de l'entité détectée avec les paires clé-valeur suivantes :

- `entityType` : le type d'entité détecté.
- `début` : la position de départ de l'entité détectée dans les données d'origine.
- `fin` : la position de fin de l'entité détectée dans les données d'origine.
- `ActionUsed` — Action exécutée sur l'entité détectée (par exemple, « DETECT », « REDACT », « PARTIAL_REDACT », « _HASH »). SHA256

Exemple :

```
{
  "DetectedEntities":{
    "SSN Col":[
      {
        "entityType":"USA_SSN",
        "actionUsed":"DETECT",
        "start":4,
        "end":15
      }
    ],
    "Random Data col":[
      {
        "entityType":"BANK_ACCOUNT",
        "actionUsed":"PARTIAL_REDACT",
        "start":4,
        "end":13
      },
      {
        "entityType":"IP_ADDRESS",
        "actionUsed":"REDACT",
        "start":4,
        "end":13
      }
    ]
  }
}
```

Paramètres de détection pour **detect()** avec des actions détaillées

Cette méthode est utilisée pour détecter des entités dans un `DynamicFrame` à l'aide de paramètres spécifiés. Il renvoie une nouvelle colonne `DataFrame` avec les valeurs d'origine remplacées par des données sensibles masquées et une colonne supplémentaire contenant des `outputColumnName` métadonnées de détection des informations personnelles.

```
detect(frame: DynamicFrame,  
       detectionParameters: JsonOptions,  
       outputColumnName: String = "DetectedEntities",  
       detectionSensitivity: String = "LOW"): DynamicFrame
```

Paramètres :

- `frame` — (type :`DynamicFrame`) : entrée `DynamicFrame` contenant les données à traiter.
- `detectionParameters` — (type :`JsonOptions`) : options JSON spécifiant les paramètres du processus de détection.
- `outputColumnName` — (type :`String`, par défaut : "DetectedEntities") : nom de la colonne dans laquelle les entités détectées seront stockées. S'il n'est pas fourni, le nom de colonne par défaut est « DetectedEntities ».
- `detectionSensitivity` — (type : `String`, options : « FAIBLE » ou « ÉLEVÉ », par défaut : « FAIBLE ») : spécifie la sensibilité du processus de détection. Les options valides sont « FAIBLE » ou « ÉLEVÉ ». Si ce n'est pas le cas, la sensibilité par défaut est réglée sur « FAIBLE ».

Paramètres `detectionParameters`

Si aucun paramètre n'est inclus, les valeurs par défaut seront utilisées.

- `action` — (type :`String`, options : « DETECT », « REDACT », « PARTIAL_REDACT », "SHA256_HASH ») Spécifie l'action à effectuer sur l'entité. Obligatoire. Notez que les actions qui effectuent un masquage (toutes sauf « DÉTECTER ») ne peuvent effectuer qu'une seule action par colonne. Il s'agit d'une mesure préventive pour masquer les entités fusionnées.
- `sourceColumns` — (type :`List[String]`, par défaut : [« * »]) liste des noms de colonnes source sur lesquels effectuer la détection pour l'entité. La valeur par défaut est [« * »] si elle n'est pas précisée. Lève une `IllegalArgumentException` si un nom de colonne non valide est utilisé.
- `sourceColumnsToExclude` — (type :`List[String]`) Liste des noms des colonnes sources sur lesquelles effectuer la détection pour l'entité. Utilisez `sourceColumns` ou

`sourceColumnsToExclude`. Lève une `IllegalArgumentException` si un nom de colonne non valide est utilisé.

- `actionOptions` : options supplémentaires basées sur l'action spécifiée :
 - Pour « DETECT » et « SHA256_HASH », aucune option n'est autorisée.
 - Pour « RÉDIGER » :
 - `redactText` — (type :String, par défaut : « ***** ») texte destiné à remplacer l'entité détectée.
 - Pour « PARTIAL_REDACT » :
 - `redactChar` — (type :String, par défaut : « * ») caractère pour remplacer chaque caractère détecté dans l'entité.
 - `matchPattern` — (type :String) modèle Regex pour la rédaction partielle. Ne peut pas être combiné avec `numLeftCharsToExclude` ou `numRightCharsToExclude`.
 - `numLeftCharsToExclude` — (type :String, integer) Nombre de caractères gauches à exclure. Ne peut pas être combiné avec `matchPattern`, mais peut être utilisé avec `numRightCharsToExclude`.
 - `numRightCharsToExclude` — (type :String, integer) Nombre de bons caractères à exclure. Ne peut pas être combiné avec `matchPattern`, mais peut être utilisé avec `numRightCharsToExclude`.

Paramètres `outputColumnName`

[Voir les `outputColumnName` paramètres](#)

Paramètres de détection pour `classifyColumns()`

Cette méthode est utilisée pour détecter des entités dans un `DynamicFrame`. Il renvoie une carte où les clés sont les noms de colonnes et les valeurs sont une liste des types d'entités détectés. Un masquage personnalisé peut être effectué une fois celui-ci renvoyé dans le AWS Glue script.

```
classifyColumns(frame: DynamicFrame,  
                entityTypeToDetect: Seq[String],  
                sampleFraction: Double = 0.1,  
                thresholdFraction: Double = 0.1,  
                detectionSensitivity: String = "LOW")
```

Paramètres :

- `frame` — (type :`DynamicFrame`) L'entrée `DynamicFrame` contenant les données à traiter.
- `entityTypesToDétecter` — (type :`Seq[String]`) Liste des types d'entités à détecter. Il peut s'agir de types d'entités gérés ou de types d'entités personnalisés.
- `sampleFraction` — (type :`Double`, par défaut : 10 %) la fraction des données à échantillonner lors de la recherche d'entités PII.
- `thresholdFraction` — (type :`Double`, par défaut : 10 %) :la fraction des données qui doit être satisfaite pour qu'une colonne soit identifiée comme données PII.
- `detectionSensitivity` — (type : `String`, options : « FAIBLE » ou « ÉLEVÉ », par défaut : « FAIBLE ») spécifie la sensibilité du processus de détection. Les options valides sont « FAIBLE » ou « ÉLEVÉ ». Si ce n'est pas le cas, la sensibilité par défaut est réglée sur « FAIBLE ».

Types de données sensibles gérés

Entités globales

Type de données	Catégorie	Description
PERSON_NAME	Universel	Le nom de la personne.
EMAIL	Personnel	L'adresse e-mail.
IP_ADDRESS	Ordinateur	Adresse IP
MAC_ADDRESS	Personnel	L'adresse MAC.

Types de données pour les États-Unis

Type de données	Description
BANK_ACCOUNT	Numéro du compte bancaire. Non spécifique à un pays ou à une région, cependant, seuls les comptes bancaires américains et canadiens sont détectés.
CREDIT_CARD	Le numéro de carte de crédit.

Type de données	Description
PHONE_NUMBER	Numéro de téléphone. Non spécifique à un pays ou à une région, cependant, seuls les numéros de téléphone américains et canadiens sont détectés pour le moment.
USA_ATIN	Le numéro d'identification fiscale américain délivré l'Internal Revenue Service.
USA_CPT_CODE	Le code CPT (spécifique aux États-Unis).
USA_DEA_NUMBER	Le numéro DEA (spécifique aux États-Unis).
USA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique aux États-Unis).
USA_HCPCS_CODE	Le code HCPCS (spécifique aux États-Unis).
USA_HEALTH_INSURANCE_CLAIM_NUMBER	Le numéro de sécurité sociale (spécifique aux États-Unis).
USA_ITIN	Le numéro ITIN (pour les ressortissants ou les entités des États-Unis).
USA_MEDICARE_BENEFICIARY_IDENTIFIER	L'identifiant de bénéficiaire Medicare (spécifique aux États-Unis).
USA_NATIONAL_DRUG_CODE	Le code NDC (spécifique aux États-Unis).
USA_NATIONAL_PROVIDER_IDENTIFIER	Le numéro National Provider Identifier (spécifique aux États-Unis).
USA_PASSPORT_NUMBER	Le numéro de passeport (pour les ressortissants des États-Unis).
USA_PTIN	Le numéro d'identification fiscale du préparateur américain délivré l'Internal Revenue Service.

Type de données	Description
USA_SSN	Le numéro de sécurité sociale (pour les ressortissants des États-Unis).

Types de données pour l'Argentine

Type de données	Description
ARGENTINA_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale de l'Argentine. Également connu sous le nom de CUIT ou CUIL.

Types de données pour l'Australie

Type de données	Description
AUSTRALIA_BUSINESS_NUMBER	Le numéro d'entreprise australien (ABN). Un identifiant unique délivré par l'Australian Business Register (ABR) pour identifier les entreprises auprès du gouvernement et de la communauté.
AUSTRALIA_COMPANY_NUMBER	Le numéro de société australien (ACN). Un identifiant unique délivré par l'Australian Securities and Investments Commission.
AUSTRALIA_DRIVING_LICENSE	Un numéro de permis de conduire pour l'Australie.
AUSTRALIA_MEDICARE_NUMBER	Le numéro Medicare australien. Un identifiant personnel délivré par l'Australian Health Insurance Commission.
AUSTRALIA_PASSPORT_NUMBER	Le numéro de passeport australien.

Type de données	Description
AUSTRALIA_TAX_FILE_NUMBER	Le numéro de dossier fiscal australien (TFN). Délivré par l'Australian Taxation Office (ATO) aux contribuables (particuliers, entreprises, etc.) pour la gestion de leurs impôts.

Types de données pour l'Autriche

Type de données	Description
AUSTRIA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à l'Autriche).
AUSTRIA_PASSPORT_NUMBER	Le numéro de passeport (spécifique à l'Autriche).
AUSTRIA_SSN	Le numéro de sécurité sociale (pour les ressortissants de l'Autriche).
AUSTRIA_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à l'Autriche).
AUSTRIA_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à l'Autriche).

Types de données pour les Balkans

Type de données	Description
BOSNIA_UNIQUE_MASTER_CITIZEN_NUMBER	Le numéro d'identification nationale (JMBG) pour les citoyens de Bosnie-Herzégovine.
KOSOVO_UNIQUE_MASTER_CITIZEN_NUMBER	Le numéro d'identification nationale (JMBG) pour le Kosovo.

Type de données	Description
MACEDONIA_UNIQUE_MASTER_CITIZEN_NUMBER	Le numéro d'identification nationale pour la Macédoine.
MONTENEGRO_UNIQUE_MASTER_CITIZEN_NUMBER	Le numéro d'identification nationale (JMBG) pour le Monténégro.
SERBIA_UNIQUE_MASTER_CITIZEN_NUMBER	Le numéro d'identification nationale (JMBG) pour la Serbie.
SERBIA_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Serbie).
VOJVODINA_UNIQUE_MASTER_CITIZEN_NUMBER	Le numéro d'identification nationale (JMBG) pour Voïvodine.

Types de données pour la Belgique

Type de données	Description
BELGIUM_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Belgique).
BELGIUM_NATIONAL_IDENTIFICATION_NUMBER	Le numéro de registre national.
BELGIUM_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Belgique).
BELGIUM_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à la Belgique).
BELGIUM_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Belgique).

Types de données pour le Brésil

Type de données	Description
BRAZIL_BANK_ACCOUNT	Le numéro de compte bancaire (spécifique au Brésil).
BRAZIL_NATIONAL_IDENTIFICATION_NUMBER	L'identifiant national (spécifique au Brésil).
BRAZIL_NATIONAL_REGISTRY_OF_LEGAL_ENTITIES_NUMBER	Le numéro d'identification délivré aux entreprises (spécifique au Brésil), également connu sous le nom de CNPJ.
BRAZIL_NATURAL_PERSON_REGISTRY_NUMBER	Le cadastre de personne physique connu sous le nom de CPF.

Types de données pour la Bulgarie

Type de données	Description
BULGARIA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Bulgarie).
BULGARIA_UNIFORM_CIVIL_NUMBER	Le numéro civil unifié (EGN) qui fait office de numéro d'identification national.
BULGARIA_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Bulgarie).

Types de données pour le Canada

Type de données	Description
CANADA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique au Canada).
CANADA_GOVERNMENT_IDENTIFICATION_CARD_NUMBER	L'identifiant national (spécifique au Canada).

Type de données	Description
CANADA_PASSPORT_NUMBER	Le numéro de passeport (spécifique au Canada).
CANADA_PERMANENT_RESIDENCE_NUMBER	Certificat d'inscription au registre des étrangers (numéro de carte RP).
CANADA_PERSONAL_HEALTH_NUMBER	L'identifiant unique pour les soins de santé (numéro PHN).
CANADA_SOCIAL_INSURANCE_NUMBER	Le numéro d'assurance sociale (SIN) au Canada.

Types de données pour le Chili

Type de données	Description
CHILE_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique au Chili).
CHILE_NATIONAL_IDENTIFICATION_NUMBER	L'identifiant national du Chili, également connu sous le nom de RUT ou RUN.

Types de données pour la Chine, Hong Kong, Macao et Taïwan

Type de données	Description
CHINA_IDENTIFICATION	L'identifiant de la Chine.
CHINA_LICENSE_PLATE_NUMBER	Le numéro de permis de conduire (spécifique à la Chine).
CHINA_MAINLAND_TRAVEL_PERMIT_ID_HONG_KONG_MACAU	Le permis de voyage continental pour les résidents de Hong Kong et de Macao.

Type de données	Description
CHINA_MAINLAND_TRAVEL_PERMIT_ID_TAIWAN	Le permis de voyage continental pour les résidents de Taïwan délivré par le gouvernement de la Chine.
CHINA_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Chine).
CHINA_PHONE_NUMBER	Le numéro de téléphone (spécifique à la Chine).
HONG_KONG_IDENTITY_CARD	Le document d'identité officiel délivré par le ministère de l'Immigration de Hong Kong.
MACAU_RESIDENT_IDENTITY_CARD	La carte d'identité de résident de Macao ou BIR est une carte d'identité officielle délivrée par le Bureau des services d'identification de Macao.
TAIWAN_NATIONAL_IDENTIFICATION_NUMBER	L'identifiant national (spécifique à Taïwan).
TAIWAN_PASSPORT_NUMBER	Le numéro de passeport (spécifique à Taïwan).

Types de données pour la Colombie

Type de données	Description
COLOMBIA_PERSONAL_IDENTIFICATION_NUMBER	Un identifiant unique attribué aux Colombiens à la naissance.
COLOMBIA_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à la Colombie).

Types de données pour la Croatie

Type de données	Description
CROATIA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Croatie).
CROATIA_IDENTITY_NUMBER	L'identifiant national (spécifique à la Croatie).
CROATIA_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Croatie).
CROATIA_PERSONAL_IDENTIFICATION_NUMBER	Le numéro d'identification personnel (OIB).

Types de données pour Chypre

Type de données	Description
CYPRUS_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à Chypre).
CYPRUS_NATIONAL_IDENTIFICATION_NUMBER	La carte d'identité chypriote.
CYPRUS_PASSPORT_NUMBER	Le numéro de passeport (spécifique à Chypre).
CYPRUS_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à Chypre).
CYPRUS_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à Chypre).

Types de données pour la Tchéquie

Type de données	Description
CZECHIA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Tchéquie).

Type de données	Description
CZECHIA_PERSONAL_IDENTIFICATION_NUMBER	Le numéro d'identification personnel (spécifique à la Tchéquie).
CZECHIA_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Tchéquie).

Types de données pour le Danemark

Type de données	Description
DENMARK_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique Danemark).
DENMARK_PERSONAL_IDENTIFICATION_NUMBER	Le numéro d'identification personnel (spécifique au Danemark).
DENMARK_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique au Danemark).
DENMARK_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique au Danemark).

Types de données pour l'Estonie

Type de données	Description
ESTONIA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à l'Estonie).
ESTONIA_PASSPORT_NUMBER	Le numéro de passeport (spécifique à l'Estonie).
ESTONIA_PERSONAL_IDENTIFICATION_CODE	Le numéro d'identification personnel (spécifique à l'Estonie).

Type de données	Description
ESTONIA_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à l'Estonie).

Types de données pour la Finlande

Type de données	Description
FINLAND_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Finlande).
FINLAND_HEALTH_INSURANCE_NUMBER	Le numéro d'assurance maladie (spécifique à la Finlande).
FINLAND_NATIONAL_IDENTIFICATION_NUMBER	Le numéro d'identifiant national (spécifique à la Finlande).
FINLAND_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Finlande).
FINLAND_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Finlande).

Types de données pour la France

Type de données	Description
FRANCE_BANK_ACCOUNT	Le numéro de compte bancaire (spécifique à la France).
FRANCE_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la France).
FRANCE_HEALTH_INSURANCE_NUMBER	Le numéro d'assurance maladie de la France.
FRANCE_INSEE_CODE	Le numéro de sécurité sociale en France.

Type de données	Description
FRANCE_NATIONAL_IDENTIFICATION_NUMBER	Le numéro d'identification national (NNI) de la France.
FRANCE_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la France).
FRANCE_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à la France).
FRANCE_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la France).

Types de données pour l'Allemagne

Type de données	Description
GERMANY_BANK_ACCOUNT	Le numéro de compte bancaire (spécifique à l'Allemagne).
GERMANY_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à l'Allemagne).
GERMANY_PASSPORT_NUMBER	Le numéro de passeport (spécifique à l'Allemagne).
GERMANY_PERSONAL_IDENTIFICATION_NUMBER	Le numéro d'identification personnel (spécifique à l'Allemagne).
GERMANY_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à l'Allemagne).
GERMANY_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à l'Allemagne).

Types de données pour la Grèce

Type de données	Description
GREECE_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Grèce).
GREECE_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Grèce).
GREECE_SSN	Le numéro de sécurité sociale (pour les ressortissants de la Grèce).
GREECE_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à la Grèce).
GREECE_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Grèce).

Types de données pour la Hongrie

Type de données	Description
HUNGARY_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Hongrie).
HUNGARY_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Hongrie).
HUNGARY_SSN	Le numéro de sécurité sociale (pour les ressortissants de la Hongrie).
HUNGARY_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à la Hongrie).
HUNGARY_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Hongrie).

Types de données pour l'Islande

Type de données	Description
ICELAND_NATIONAL_IDENTIFICATION_NUMBER	L'identifiant national (spécifique à l'Islande).
ICELAND_PASSPORT_NUMBER	Le numéro de passeport (spécifique à l'Islande).
ICELAND_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à l'Islande).

Types de données pour l'Inde

Type de données	Description
INDIA_AADHAAR_NUMBER	Le numéro d'identification Aadhaar délivré par l'Unique Identification Authority of India.
INDIA_PERMANENT_ACCOUNT_NUMBER	Le numéro PAN (Permanent Account Number, numéro de compte permanent).

Types de données pour l'Indonésie

Type de données	Description
INDONESIA_IDENTITY_CARD_NUMBER	L'identifiant national (spécifique à l'Indonésie).

Types de données pour l'Irlande

Type de données	Description
IRELAND_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à l'Irlande).
IRELAND_PASSPORT_NUMBER	Le numéro de passeport (spécifique à l'Irlande).

Type de données	Description
IRELAND_PERSONAL_PUBLIC_SERVICE_NUMBER	Le numéro personnel pour le service public (PPS) de l'Irlande.
IRELAND_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à l'Irlande).
IRELAND_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à l'Irlande).

Types de données pour Israël

Type de données	Description
ISRAEL_IDENTIFICATION_NUMBER	L'identifiant national (spécifique à Israël).

Types de données pour l'Italie

Type de données	Description
ITALY_BANK_ACCOUNT	Le numéro de compte bancaire (spécifique à l'Italie).
ITALY_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à l'Italie).
ITALY_FISCAL_CODE	Le numéro d'identification, également connu sous le nom de Codice Fiscale italien.
ITALY_PASSPORT_NUMBER	Le numéro de passeport (spécifique à l'Italie).
ITALY_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à l'Italie).

Types de données pour le Japon

Type de données	Description
JAPAN_BANK_ACCOUNT	Compte en banque au Japon.
JAPAN_DRIVING_LICENSE	Un numéro de permis de conduire pour le Japon.
JAPAN_MY_NUMBER	Identifiant unique des citoyens ou des entreprises du Japon utilisé pour l'administration fiscale, la sécurité sociale et les interventions en cas de catastrophe
JAPAN_PASSPORT_NUMBER	Numéro de passeport japonais.

Types de données pour la Corée

Type de données	Description
KOREA_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Corée).
KOREA_RESIDENCE_REGISTRATION_NUMBER_FOR_CITIZENS	Le numéro d'enregistrement de résident en Corée pour les résidents.
KOREA_RESIDENCE_REGISTRATION_NUMBER_FOR_FOREIGNERS	Le numéro d'enregistrement de résident en Corée pour les étrangers.

Types de données pour la Lettonie

Type de données	Description
LATVIA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Lettonie).
LATVIA_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Lettonie).

Type de données	Description
LATVIA_PERSONAL_IDENTIFICATION_NUMBER	Le numéro d'identification personnel (spécifique à la Lettonie).
LATVIA_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Lettonie).

Types de données pour le Liechtenstein

Type de données	Description
LIECHTENSTEIN_NATIONAL_IDENTIFICATION_NUMBER	L'identifiant national (spécifique au Liechtenstein).
LIECHTENSTEIN_PASSPORT_NUMBER	Le numéro de passeport (spécifique au Liechtenstein).
LIECHTENSTEIN_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique au Liechtenstein).

Types de données pour la Lituanie

Type de données	Description
LITHUANIA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Lituanie).
LITHUANIA_PERSONAL_IDENTIFICATION_NUMBER	Le numéro d'identification personnel (spécifique à la Lituanie).
LITHUANIA_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à la Lituanie).
LITHUANIA_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Lituanie).

Types de données pour le Luxembourg

Type de données	Description
LUXEMBOURG_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique au Luxembourg).
LUXEMBOURG_NATIONAL_INDIVIDUAL_NUMBER	L'identifiant national (spécifique au Luxembourg).
LUXEMBOURG_PASSPORT_NUMBER	Le numéro de passeport (spécifique au Luxembourg).
LUXEMBOURG_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique au Luxembourg).
LUXEMBOURG_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique au Luxembourg).

Types de données pour la Malaisie

Type de données	Description
MALAYSIA_MYKAD_NUMBER	L'identifiant national (spécifique à la Malaisie).
MALAYSIA_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Malaisie).

Types de données pour Malte

Type de données	Description
MALTA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à Malte).
MALTA_NATIONAL_IDENTIFICATION_NUMBER	L'identifiant national (spécifique à Malte).

Type de données	Description
MALTA_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à Malte).
MALTA_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à Malte).

Types de données pour le Mexique

Type de données	Description
MEXICO_CLABE_NUMBER	Numéro CLABE du Mexique (Clave Bancaria Estandarizada), numéro bancaire.
MEXICO_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique au Mexique).
MEXICO_PASSPORT_NUMBER	Le numéro de passeport (spécifique au Mexique).
MEXICO_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique au Mexique).
MEXICO_UNIQUE_POPULATION_REGISTRY_CODE	Le Clave Única de Registro de Población (CURP), le numéro d'identification national au Mexique.

Types de données pour les Pays-Bas

Type de données	Description
NETHERLANDS_CITIZEN_SERVICE_NUMBER	Le numéro de citoyen néerlandais (BSN, burgerservicenummer).
NETHERLANDS_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique aux Pays-Bas).

Type de données	Description
NETHERLANDS_PASSPORT_NUMBER	Le numéro de passeport (spécifique aux Pays-Bas).
NETHERLANDS_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique aux Pays-Bas).
NETHERLANDS_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique aux Pays-Bas).
NETHERLANDS_BANK_ACCOUNT	Le numéro de compte bancaire (spécifique aux Pays-Bas).

Types de données pour la Nouvelle-Zélande

Type de données	Description
NEW_ZEALAND_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Nouvelle-Zélande).
NEW_ZEALAND_NATIONAL_HEALTH_INDEX_NUMBER	Le numéro de l'indice national de santé (NHI) de la Nouvelle-Zélande.
NEW_ZEALAND_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale, également connu sous le nom de numéro de revenu intérieur (spécifique à la Nouvelle-Zélande).

Types de données pour la Norvège

Type de données	Description
NORWAY_BIRTH_NUMBER	Le numéro d'identité national norvégien.
NORWAY_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Norvège).

Type de données	Description
NORWAY_HEALTH_INSURANCE_NUMBER	Le numéro d'assurance maladie de la Norvège.
NORWAY_NATIONAL_IDENTIFICATION_NUMBER	Le numéro d'identifiant national (spécifique à la Norvège).
NORWAY_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Norvège).

Types de données pour les Philippines

Type de données	Description
PHILIPPINES_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique aux Philippines).
PHILIPPINES_PASSPORT_NUMBER	Le numéro de passeport (spécifique aux Philippines).

Types de données pour la Pologne

Type de données	Description
POLAND_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Pologne).
POLAND_IDENTIFICATION_NUMBER	Le numéro d'identification polonais.
POLAND_PASSPORT_NUMBER	Le numéro du passeport (spécifique à la Pologne).
POLAND_REGON_NUMBER	Le numéro d'identification REGON.
POLAND_SSN	Le numéro de sécurité sociale (pour les ressortissants de la Pologne).

Type de données	Description
POLAND_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à la Pologne).
POLAND_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Pologne).

Types de données pour le Portugal

Type de données	Description
PORTUGAL_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique au Portugal).
PORTUGAL_NATIONAL_IDENTIFICATION_NUMBER	Le numéro d'identifiant national (spécifique au Portugal).
PORTUGAL_PASSPORT_NUMBER	Le numéro de passeport (spécifique au Portugal).
PORTUGAL_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique au Portugal).
PORTUGAL_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique au Portugal).

Types de données pour la Roumanie

Type de données	Description
ROMANIA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Roumanie).
ROMANIA_NUMERICAL_PERSONAL_CODE	Le numéro d'identification personnel (spécifique à la Roumanie).

Type de données	Description
ROMANIA_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Roumanie).
ROMANIA_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Roumanie).

Types de données pour Singapour

Type de données	Description
SINGAPORE_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à Singapour).
SINGAPORE_NATIONAL_REGISTRY_IDENTIFICATION_NUMBER	La carte d'identité nationale d'enregistrement pour Singapour.
SINGAPORE_PASSPORT_NUMBER	Le numéro de passeport (spécifique à Singapour).
SINGAPORE_UNIQUE_ENTITY_NUMBER	Le numéro d'entité unique pour Singapour.

Types de données pour la Slovaquie

Type de données	Description
SLOVAKIA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Slovaquie).
SLOVAKIA_NATIONAL_IDENTIFICATION_NUMBER	Le numéro d'identifiant national (spécifique à la Slovaquie).
SLOVAKIA_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Slovaquie).

Type de données	Description
SLOVAKIA_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Slovaquie).

Types de données pour la Slovaquie

Type de données	Description
SLOVENIA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Slovaquie).
SLOVENIA_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Slovaquie).
SLOVENIA_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale (spécifique à la Slovaquie).
SLOVENIA_UNIQUE_MASTER_CITIZEN_NUMBER	Le numéro d'identification nationale (JMBG) pour les citoyens slovaques.
SLOVENIA_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Slovaquie).

Types de données pour l'Afrique du Sud

Type de données	Description
SOUTH_AFRICA_PERSONAL_IDENTIFICATION_NUMBER	Le numéro d'identification personnel (spécifique à l'Afrique du Sud).

Types de données pour l'Espagne

Type de données	Description
SPAIN_BANK_ACCOUNT	Le numéro de compte bancaire (spécifique à l'Espagne).
SPAIN_DNI	La carte d'identité nationale (Documento Nacional de Identidad) de l'Espagne.
SPAIN_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à l'Espagne).
SPAIN_NIE	Le numéro d'identité d'étranger (spécifique à l'Espagne), également connu sous le nom de NIE.
SPAIN_NIF	Le numéro d'identification fiscale (spécifique à l'Espagne), également connu sous le nom de NIF.
SPAIN_PASSPORT_NUMBER	Le numéro de passeport (spécifique à l'Espagne).
SPAIN_SSN	Le numéro de sécurité sociale (pour les ressortissants de l'Espagne).
SPAIN_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à l'Espagne).

Types de données pour le Sri Lanka

Type de données	Description
SRI_LANKA_NATIONAL_IDENTIFICATION_NUMBER	Le numéro d'identifiant national (spécifique au Sri Lanka).

Types de données pour la Suède

Type de données	Description
SWEDEN_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique à la Suède).
SWEDEN_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Suède).
SWEDEN_PERSONAL_IDENTIFICATION_NUMBER	Le numéro d'identifiant national (spécifique à la Suède).
SWEDEN_TAX_IDENTIFICATION_NUMBER	Le numéro d'identification fiscale suédois (personnummer).
SWEDEN_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Suède).

Types de données pour la Suisse

Type de données	Description
SWITZERLAND_AHV	Le numéro de sécurité sociale pour les ressortissants suisses (AHV).
SWITZERLAND_HEALTH_INSURANCE_NUMBER	Le numéro d'assurance maladie de la Suisse.
SWITZERLAND_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Suisse).
SWITZERLAND_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Suisse).

Types de données pour la Thaïlande

Type de données	Description
THAILAND_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Thaïlande).
THAILAND_PERSONAL_IDENTIFICATION_NUMBER	Le numéro d'identification personnel (spécifique à la Thaïlande).

Types de données pour la Turquie

Type de données	Description
TURKEY_NATIONAL_IDENTIFICATION_NUMBER	Le numéro d'identifiant national (spécifique à la Turquie).
TURKEY_PASSPORT_NUMBER	Le numéro de passeport (spécifique à la Turquie).
TURKEY_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique à la Turquie).

Types de données pour l'Ukraine

Type de données	Description
UKRAINE_INDIVIDUAL_IDENTIFICATION_NUMBER	L'identifiant unique (spécifique à l'Ukraine).
UKRAINE_PASSPORT_NUMBER_DOMESTIC	Le numéro de passeport national (spécifique à l'Ukraine).
UKRAINE_PASSPORT_NUMBER_INTERNATIONAL	Le numéro de passeport international (spécifique à l'Ukraine).

Types de données pour les Émirats arabes unis (EAU)

Type de données	Description
UNITED_ARAB_EMIRATES_PERSONAL_NUMBER	Le numéro d'identification personnel (spécifique aux EAU).

Types de données pour le Royaume-Uni

Type de données	Description
UK_BANK_ACCOUNT	Le compte bancaire au Royaume-Uni (UK).
UK_BANK_SORT_CODE	Le Sort code du Royaume-Uni (UK). Les Sort Codes sont des codes bancaires utilisés pour acheminer les transferts d'argent entre les banques de leurs pays respectifs via leurs organismes de compensation respectifs.
UK_DRIVING_LICENSE	Numéro de permis de conduire pour le Royaume-Uni de Grande-Bretagne et d'Irlande du Nord (spécifique au Royaume-Uni)
UK_ELECTORAL_ROLL_NUMBER	L'Electoral Roll Number (ERN) est le numéro d'identification délivré aux citoyens pour s'inscrire aux élections du Royaume-Uni. Le format de ce numéro est spécifié par les normes du Bureau du Cabinet du gouvernement du Royaume-Uni.
UK_NATIONAL_HEALTH_SERVICE_NUMBER	Le National Health Service (NHS) est le numéro unique attribué aux utilisateurs enregistrés auprès des services de santé publique du Royaume-Uni.
UK_NATIONAL_INSURANCE_NUMBER	Le National Insurance Number (NINO) est un numéro utilisé au Royaume-Uni pour identifier une personne inscrite au régime national

Type de données	Description
	d'assurance ou au système de sécurité sociale. Ce numéro est parfois appelé NI No ou NINO.
UK_PASSPORT_NUMBER	Le numéro de passeport du Royaume-Uni (UK).
UK_UNIQUE_TAXPAYER_REFERENCE_NUMBER	Numéro de référence fiscale (UTR) du Royaume-Uni. Identifiant utilisé par le gouvernement du Royaume-Uni pour gérer le système fiscal.
UK_VALUE_ADDED_TAX	La TVA est une taxe à la consommation qui est prise en charge par le consommateur final. La TVA est payée pour chaque transaction du processus de fabrication et de distribution. Pour le Royaume-Uni, le numéro de TVA est délivré par le bureau de TVA de la région dans laquelle l'entreprise est établie.
UK_PHONE_NUMBER	Le numéro de téléphone du Royaume-Uni (UK).

Types de données pour le Venezuela

Type de données	Description
VENEZUELA_DRIVING_LICENSE	Le numéro de permis de conduire (spécifique au Venezuela).
VENEZUELA_NATIONAL_IDENTIFICATION_NUMBER	Le numéro d'identifiant national (spécifique au Venezuela).
VENEZUELA_VALUE_ADDED_TAX	La taxe sur la valeur ajoutée (spécifique au Venezuela).

Utilisation d'une détection détaillée des données sensibles

Note

Les actions détaillées ne sont disponibles que dans AWS Glue 3.0 et 4.0. Cela inclut le AWS Glue Studio expérience. Les modifications persistantes du journal d'audit ne sont pas non plus disponibles dans la version 2.0.

Tous AWS Glue Studio Les jobs visuels des versions 3.0 et 4.0 comporteront un script créé qui utilisera automatiquement des actions précises. APIs

La transformation Detect Sensitive Data permet de détecter, de masquer ou de supprimer des entités que vous définissez ou qui sont prédéfinies par AWS Glue. Les actions détaillées vous permettent en outre d'appliquer une action spécifique par entité. Les avantages supplémentaires incluent :

- Performances améliorées, car les actions sont appliquées dès que des données sont détectées.
- La possibilité d'inclure ou exclure des colonnes spécifiques.
- La possibilité d'utiliser un masquage partiel. Cela vous permet de masquer partiellement les entités de données sensibles détectées, plutôt que de masquer la chaîne entière. Les deux paramètres simples avec décalages et regex sont pris en charge.

Vous trouverez ci-dessous des extraits de code relatifs à la détection de données sensibles APIs et des actions détaillées utilisées dans les exemples de tâches mentionnés dans la section suivante.

API de détection : les actions détaillées utilisent le nouveau paramètre `detectionParameters` :

```
def detect(  
    frame: DynamicFrame,  
    detectionParameters: JsonOptions,  
    outputColumnName: String = "DetectedEntities",  
    detectionSensitivity: String = "LOW"  
): DynamicFrame = {}
```

Utilisation de la détection des données sensibles APIs avec des actions précises

La détection des données sensibles APIs à l'aide de la fonction de détection analyse les données fournies, détermine si les lignes ou les colonnes sont des types d'entités de données sensibles et exécute les actions spécifiées par l'utilisateur pour chaque type d'entité.

Utilisation de l'API de détection avec des actions détaillées

Utilisez l'API de détection et spécifiez le `outputColumnName` et `detectionParameters`.

```
object GlueApp {
  def main(sysArgs: Array[String]) {

    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    // @params: [JOB_NAME]
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    // Script generated for node S3 bucket. Creates DataFrame from data stored in
    S3.
    val S3bucket_node1 =
glueContext.getSourceWithFormat(formatOptions=JsonOptions("""{"quoteChar":
"\\"", "withHeader": true, "separator": ",", "optimizePerformance": false}"""),
connectionType="s3", format="csv", options=JsonOptions("""{"paths":
["s3://189657479688-ddevansh-pii-test-bucket/tiny_pii.csv"], "recurse": true}"""),
transformationContext="S3bucket_node1").getDynamicFrame()

    // Script generated for node Detect Sensitive Data. Will run detect API for the
    DataFrame
    // detectionParameter contains information on which EntityType are being
    detected
    // and what actions are being applied to them when detected.
    val DetectSensitiveData_node2 = EntityDetector.detect(
      frame = S3bucket_node1,
      detectionParameters = JsonOptions(
        """
        {
          "PHONE_NUMBER": [
            {
              "action": "PARTIAL_REDACT",
              "actionOptions": {
                "numLeftCharsToExclude": "3",
                "numRightCharsToExclude": "4",
                "redactChar": "#"
              },
              "sourceColumnsToExclude": [ "Passport No", "DL NO#" ]
            }
          ]
        }
        """)
    )
  }
}
```

```

        ],
        "USA_PASSPORT_NUMBER": [
            {
                "action": "SHA256_HASH",
                "sourceColumns": [ "Passport No" ]
            }
        ],
        "USA_DRIVING_LICENSE": [
            {
                "action": "REDACT",
                "actionOptions": {
                    "redactText": "USA_DL"
                },
                "sourceColumns": [ "DL NO#" ]
            }
        ]
    }
}

outputColumnName = "DetectedEntities"
)

// Script generated for node S3 bucket. Store Results of detect to S3 location
val S3bucket_node3 = glueContext.getSinkWithFormat(connectionType="s3",
options=JsonOptions("""{"path": "s3://amzn-s3-demo-bucket/test-output/",
"partitionKeys": []}"""), transformationContext="S3bucket_node3",
format="json").writeDynamicFrame(DetectSensitiveData_node2)

Job.commit()
}

```

Le script ci-dessus créera un DataFrame à partir d'un emplacement dans Amazon S3, puis exécutera l'API `detectAPI`. Étant donné que l'API `detectAPI` exige que le champ `detectionParameters` (une carte du nom de l'entité avec une liste de tous les paramètres d'action à utiliser pour cette entité) soit représenté par l'objet `JsonOptions` de AWS Glue, cela nous permettra également d'étendre les fonctionnalités de l'API.

Pour chaque action spécifiée par entité, créez une liste de tous les noms de colonnes auxquels appliquer la combinaison entité/action. Cela vous permet de personnaliser les entités à détecter pour

chaque colonne de votre jeu de données et d'ignorer les entités dont vous savez qu'elles ne figurent pas dans une colonne spécifique. Cela permet également à vos tâches d'être plus performantes en n'effectuant pas d'appels de détection inutiles à ces entités et en vous permettant d'effectuer des actions uniques pour chaque combinaison de colonnes et d'entités.

En examinant de plus près les `detectionParameters`, il existe trois types d'entités dans l'exemple de tâche. Il s'agit des `Phone Number`, `USA_PASSPORT_NUMBER`, et `USA_DRIVING_LICENSE`. Pour chacun de ces types d'entités, AWS Glue exécutera différentes actions, à `PARTIAL_REDACT` savoir `SHA256_HASH`, `REDACT`, et `DETECT`. Chacun des types d'entités a également des `sourceColumns` auxquelles s'appliquer et/ou des `sourceColumnsToExclude` si elles sont détectées.

Note

Une seule edit-in-place action (`PARTIAL_REDACT`, `SHA256_HASH`, ou `REDACT`) peut être utilisée par colonne, mais l'`DETECT` action peut être utilisée avec n'importe laquelle de ces actions.

La disposition du champ `detectionParameters` est la suivante :

```
ENTITY_NAME -> List[Actions]
{
  "ENTITY_NAME": [{
    Action, // required
    ColumnSpecs,
    ActionOptionsMap
  }],
  "ENTITY_NAME2": [{
    ...
  }]
}
```

Les types d'actions et `actionOptions` sont répertoriés ci-dessous :

```
DETECT
{
  # Required
```

```

    "action": "DETECT",
    # Optional, depending on action chosen
    "actionOptions": {
        // There are no actionOptions for DETECT
    },
    # 1 of below required, both can also used
    "sourceColumns": [
        "COL_1", "COL_2", ..., "COL_N"
    ],
    "sourceColumnsToExclude": [
        "COL_5"
    ]
}

SHA256_HASH
{
    # Required
    "action": "SHA256_HASH",
    # Required or optional, depending on action chosen
    "actionOptions": {
        // There are no actionOptions for SHA256_HASH
    },

    # 1 of below required, both can also used
    "sourceColumns": [
        "COL_1", "COL_2", ..., "COL_N"
    ],
    "sourceColumnsToExclude": [
        "COL_5"
    ]
}

REDACT
{
    # Required
    "action": "REDACT",
    # Required or optional, depending on action chosen
    "actionOptions": {
        // The text that is being replaced
        "redactText": "USA_DL"
    },

    # 1 of below required, both can also used
    "sourceColumns": [

```

```

        "COL_1", "COL_2", ..., "COL_N"
    ],
    "sourceColumnsToExclude": [
        "COL_5"
    ]
}

PARTIAL_REDACT
{
    # Required
    "action": "PARTIAL_REDACT",
    # Required or optional, depending on action chosen
    "actionOptions": {
        // number of characters to not redact from the left side
        "numLeftCharsToExclude": "3",
        // number of characters to not redact from the right side
        "numRightCharsToExclude": "4",
        // the partial redact will be made with this redacted character
        "redactChar": "#",
        // regex pattern for partial redaction
        "matchPattern": "[0-9]"
    },

    # 1 of below required, both can also used
    "sourceColumns": [
        "COL_1", "COL_2", ..., "COL_N"
    ],
    "sourceColumnsToExclude": [
        "COL_5"
    ]
}

```

Une fois le script exécuté, les résultats sont envoyés à l'emplacement Amazon S3 indiqué. Vous pouvez afficher vos données dans Amazon S3, mais les types d'entités sélectionnés sont sensibilisés en fonction de l'action sélectionnée. Dans ce cas, nous aurions une ligne qui ressemblerait à ceci :

```

{
    "Name": "Colby Schuster",
    "Address": "39041 Antonietta Vista, South Rodgerside, Nebraska 24151",
    "Car Owned": "Fiat",
    "Email": "Kitty46@gmail.com",
    "Company": "O'Reilly Group",

```

```
"Job Title": "Dynamic Functionality Facilitator",
"ITIN": "991-22-2906",
"Username": "Cassandre.Kub43",
"SSN": "914-22-2906",
"DOB": "2020-08-27",
"Phone Number": "1-2#####1718",
"Bank Account No": "69741187",
"Credit Card Number": "6441-6289-6867-2162-2711",
"Passport No": "94f311e93a623c72ccb6fc46cf5f5b0265ccb42c517498a0f27fd4c43b47111e",
"DL NO#": "USA_DL"
}
```

Dans le script ci-dessus, le Phone Number a été partiellement expurgé avec #. Passport Noll a été transformé en SHA256 hachage. Le DL NO# a été détecté comme un numéro de permis de conduire américain et a été expurgé en « USA_DL », comme indiqué dans les `detectionParameters`.

Note

L'API `classifyColumns` n'est pas disponible pour une utilisation avec des actions détaillées en raison de la nature de l'API. Cette API effectue un échantillonnage de colonnes (ajustable par l'utilisateur mais possède des valeurs par défaut) pour effectuer la détection plus rapidement. Pour cette raison, les actions détaillées nécessitent une itération sur chaque valeur.

Journal d'audit permanent

Une nouvelle fonctionnalité introduite avec des actions précises (mais également disponible en cas d'utilisation normale APIs) est la présence d'un journal d'audit permanent. Actuellement, l'exécution de l'API de détection ajoute un paramètre de colonne supplémentaire (par défaut `DetectedEntities` mais personnalisable via le `outputColumnName`) avec les métadonnées de détection des informations personnelles identifiables. Cela possède désormais une clé de métadonnées « `actionUsed` », qui est l'une des valeurs `DETECT`, `PARTIAL_REDACT`, `SHA256_HASH`, `REDACT`.

```
"DetectedEntities": {
  "Credit Card Number": [
    {
      "entityType": "CREDIT_CARD",
```

```

        "actionUsed": "DETECT",
        "start": 0,
        "end": 19
    },
    ],
    "Phone Number": [
        {
            "entityType": "PHONE_NUMBER",
            "actionUsed": "REDACT",
            "start": 0,
            "end": 14
        }
    ]
}

```

Même les clients qui n'ont APIs pas recours à des actions précises, telles que celles-ci, `detect(entityTypesToDetect, outputColumnName)` verront ce journal d'audit permanent s'afficher dans la trame de données qui en résulte.

Les clients utilisant APIs des actions détaillées verront toutes les actions, qu'elles soient expurgées ou non. Exemple :

```

+-----+-----+
+-----+-----+
+
| Credit Card Number | Phone Number |
|                                     |
|                                     |
+-----+-----+
+-----+-----+
+
| 622126741306XXXX | +12#####7890 | {"Credit Card Number":
[{"entityType":"CREDIT_CARD","actionUsed":"PARTIAL_REDACT","start":0,"end":16}], "Phone
Number":
[{"entityType":"PHONE_NUMBER","actionUsed":"PARTIAL_REDACT","start":0,"end":12}]} |
| 6221 2674 1306 XXXX | +12#####7890 | {"Credit Card Number":
[{"entityType":"CREDIT_CARD","actionUsed":"PARTIAL_REDACT","start":0,"end":19}], "Phone
Number":
[{"entityType":"PHONE_NUMBER","actionUsed":"PARTIAL_REDACT","start":0,"end":14}]} |
| 6221-2674-1306-XXXX | 22#####7890 | {"Credit Card Number":
[{"entityType":"CREDIT_CARD","actionUsed":"PARTIAL_REDACT","start":0,"end":19}], "Phone

```

```
Number":
[{"entityType":"PHONE_NUMBER","actionUsed":"PARTIAL_REDACT","start":0,"end":14}]]} |
+-----+-----
+-----+-----
+
```

Si vous ne souhaitez pas voir la `DetectedEntities` colonne, vous pouvez simplement supprimer la colonne supplémentaire dans un script personnalisé.

AWS Glue API Visual Job

AWS Glue fournit une API qui permet aux clients de créer des tâches d'intégration de données à l'aide du AWS Glue API provenant d'un objet JSON qui représente un flux de travail par étapes visuelles. Les clients peuvent ensuite utiliser l'éditeur visuel dans AWS Glue Studio pour travailler avec ces emplois.

Pour plus d'informations sur le types de données de l'API Visual Job, voir [API Visual Job](#).

Rubriques

- [Conception d'API et CRUD APIs](#)
- [Premiers pas](#)
- [Limitations de tâche visuelle](#)

Conception d'API et CRUD APIs

Les `CreateJob` et `UpdateJob` [APIs](#) désormais en charge un paramètre optionnel supplémentaire, `codegenConfiguration` les nœuds. Si vous fournissez une structure JSON non vide pour ce champ, le DAG sera enregistré dans AWS Glue Studio pour la tâche créée et le code associé généré. Une valeur null ou une chaîne vide pour ce champ lors de la création de la tâche sera ignorée.

Les mises à jour du champ `codegenConfiguration` Nœuds seront effectuées par le biais du `UpdateJob` AWS Glue API de la même manière que `CreateJob`. Le champ entier doit être spécifié `UpdateJob` là où le DAG a été modifié comme vous le souhaitez. Une valeur null fournie sera ignorée et aucune mise à jour du DAG ne sera effectuée. Une structure ou une chaîne vide entraînera la définition `codegenConfiguration` des nœuds comme vides et la suppression de tout DAG précédent. L' `GetJob` API renverra un DAG s'il en existe un. L' `DeleteJob` API supprimera également tout DAG associé.

Premiers pas

Pour créer une tâche, utilisez l' [CreateJob action](#). L'entrée de CreateJob demande comportera un champ supplémentaire « codeGenConfiguration Nodes » dans lequel vous pourrez spécifier l'objet DAG en JSON.

Points à garder à l'esprit :

- Le champ « codeGenConfiguration Nodes » est une carte entre NodeID et nœud.
- Chaque nœud commence par une clé identifiant de quel type de nœud il s'agit.
- Il ne peut y avoir qu'une seule clé spécifiée car un nœud ne peut être que d'un seul type.
- Le champ de saisie contient les nœuds parents du nœud actuel.

Ce qui suit est une représentation JSON d'une CreateJobentrée.

```
{
  "node-1": {
    "S3CatalogSource": {
      "Table": "csvFormattedTable",
      "PartitionPredicate": "",
      "Name": "S3 bucket",
      "AdditionalOptions": {},
      "Database": "myDatabase"
    }
  },
  "node-3": {
    "S3DirectTarget": {
      "Inputs": ["node-2"],
      "PartitionKeys": [],
      "Compression": "none",
      "Format": "json",
      "SchemaChangePolicy": { "EnableUpdateCatalog": false },
      "Path": "",
      "Name": "S3 bucket"
    }
  },
  "node-2": {
    "ApplyMapping": {
      "Inputs": ["node-1"],
      "Name": "ApplyMapping",
      "Mapping": [
```

```
{
  "FromType": "long",
  "ToType": "long",
  "Dropped": false,
  "ToKey": "myheader1",
  "FromPath": ["myheader1"]
},
{
  "FromType": "long",
  "ToType": "long",
  "Dropped": false,
  "ToKey": "myheader2",
  "FromPath": ["myheader2"]
},
{
  "FromType": "long",
  "ToType": "long",
  "Dropped": false,
  "ToKey": "myheader3",
  "FromPath": ["myheader3"]
}
]
}
}
```

Mise à jour et obtention de tâches

Comme il UpdateJob aura également un champ « codeGenConfiguration Nœuds », le format de saisie sera le même. Voir [UpdateJobAction](#).

L'GetJobaction renverra également un champ « codeGenConfiguration Nœuds » dans le même format. Voir [GetJobAction](#).

Limitations de tâche visuelle

Étant donné que le paramètre codeGenConfiguration « Nodes » a été ajouté au paramètre existant APIs, toutes les limites de celui-ci APIs seront héritées. De plus, la taille des codeGenConfiguration nœuds et de certains nœuds sera limitée. Pour plus d'informations, voir [Structure de tâche](#).

Programmation de scripts Ray

AWS Glue facilite l'écriture et l'exécution de scripts Ray. Cette section décrit les fonctionnalités Ray prises en charge et disponibles dans AWS Glue for Ray. Vous programmez des scripts Ray dans Python.

Votre script personnalisé doit être compatible avec la version de Ray définie par le champ `Runtime` de votre définition de tâche. Pour plus d'informations relatives aux `Runtime` dans l'API Tâche, consultez [the section called “Tâches”](#). Pour en savoir plus chaque environnement d'exécution, consultez [the section called “Environnements d'exécution Ray pris en charge”](#).

Rubriques

- [Tutoriel : Écrire un script ETL AWS Glue pour Ray](#)
- [Utiliser Ray Core et Ray Data AWS Glue pour Ray](#)
- [Fournir des fichiers et des bibliothèques Python aux tâches Ray](#)
- [Connexion aux données dans les tâches Ray](#)

Tutoriel : Écrire un script ETL AWS Glue pour Ray

Ray vous permet d'écrire et de dimensionner des tâches distribuées de manière native en Python. AWS Glue for Ray propose des environnements Ray sans serveur auxquels vous pouvez accéder à la fois à partir de tâches et de sessions interactives (les sessions interactives Ray sont en version préliminaire). Le système de AWS Glue tâches fournit un moyen cohérent de gérer et d'exécuter vos tâches, selon un calendrier, à partir d'un déclencheur ou depuis la console. AWS Glue

La combinaison de ces AWS Glue outils crée une puissante chaîne d'outils que vous pouvez utiliser pour les charges de travail d'extraction, de transformation et de chargement (ETL), un cas d'utilisation populaire. AWS Glue Dans ce didacticiel, vous apprendrez les bases de la mise en place de cette solution.

Nous prenons également en charge l'utilisation AWS Glue de Spark pour vos charges de travail ETL. Pour un didacticiel sur l'écriture d'un script AWS Glue pour Spark, consultez [the section called “Didacticiel : rédiger un script Spark”](#). Pour plus d'informations sur les moteurs disponibles, consultez [the section called “AWS Glue pour Spark et AWS Glue pour Ray”](#). Ray est capable de traiter de nombreux types de tâches dans les domaines de l'analyse, du machine learning (ML) et du développement d'applications.

Dans ce didacticiel, vous allez extraire, transformer et charger un jeu de données CSV hébergé dans Amazon Simple Storage Service (Amazon S3). Vous allez commencer par le jeu de données d'enregistrement de voyages de l'agence New York City Taxi and Limousine Commission (TLC), qui est stocké dans un compartiment Amazon S3 public. Pour plus d'informations sur ce jeu de données, consultez le [Registre des données ouvertes sur AWS](#).

Vous transformerez vos données à l'aide de transformations prédéfinies disponibles dans la bibliothèque Ray Data. Ray Data est une bibliothèque de préparation de jeux de données conçue par Ray et incluse par défaut dans AWS Glue les environnements for Ray. Pour plus d'informations sur les bibliothèques incluses par défaut, consultez [the section called “Modules fournis avec les tâches Ray”](#). Vous écrirez ensuite vos données transformées dans un compartiment Amazon S3 que vous contrôlez.

Conditions préalables — Pour ce didacticiel, vous avez besoin d'un AWS compte avec accès à Amazon S3 AWS Glue et à Amazon S3.

Étape 1 : créer un compartiment dans Amazon S3 pour stocker vos données de sortie

Vous aurez besoin d'un compartiment Amazon S3 que vous contrôlez pour servir de récepteur pour les données créées dans ce didacticiel. Vous pouvez créer ce compartiment en procédant comme suit.


Note

Si vous souhaitez écrire vos données dans un compartiment existant que vous contrôlez, vous pouvez ignorer cette étape. Prenez note du *yourBucketName* nom du compartiment existant, à utiliser ultérieurement.

Pour créer un compartiment pour la sortie de votre tâche Ray

- Créez un compartiment en suivant les étapes décrites dans la section [Créer un compartiment](#) du Guide de l'utilisateur Amazon S3.
 - Lorsque vous choisissez un nom de bucket, prenez-en note *yourBucketName*, auquel vous vous référerez dans les étapes suivantes.
 - Pour les autres configurations, les paramètres suggérés fournis dans la console Amazon S3 devraient fonctionner correctement dans ce didacticiel.

Par exemple, la boîte de dialogue de création de compartiments peut ressembler à ceci dans la console Amazon S3.



Amazon S3 > Buckets > Create bucket

Create bucket [Info](#)

Buckets are containers for data stored in S3. [Learn more](#)

General configuration

Bucket name

Bucket name must be globally unique and must not contain spaces or uppercase letters. [See rules for bucket naming](#)

AWS Region

US East (N. Virginia) us-east-1 ▼

Étape 2 : créer un rôle IAM pour votre politique pour votre tâche Ray

Votre travail nécessitera un rôle AWS Identity and Access Management (IAM) présentant les caractéristiques suivantes :

- Autorisations accordées par la politique gérée `AWSGlueServiceRole`. Il s'agit des autorisations de base nécessaires pour exécuter une AWS Glue tâche.
- Autorisations du niveau d'accès `Read` pour la ressource Amazon S3 `nyc-tlc/*`.
- Autorisations du niveau d'accès `Write` pour la ressource Amazon S3 `yourBucketName/*`.
- Une relation de confiance qui permet au principal `glue.amazonaws.com` d'assumer le rôle.

Vous pouvez créer ce rôle en procédant comme suit.

Pour créer un rôle IAM pour votre job AWS Glue for Ray

Note

Vous pouvez créer un rôle IAM en suivant de nombreuses procédures différentes. Pour plus d'informations ou d'options sur le provisionnement des ressources IAM, consultez la [documentation AWS Identity and Access Management](#).

1. Créez une politique qui définit les autorisations Amazon S3 décrites précédemment en suivant les étapes décrites dans la section [Création de politiques avec l'éditeur visuel](#) du Guide de l'utilisateur IAM.
 - Lorsque vous sélectionnez un service, choisissez Amazon S3.
 - Lorsque vous sélectionnez des autorisations pour votre politique, associez les ensembles d'actions suivants pour les ressources suivantes (mentionnées précédemment) :
 - Autorisations du niveau d'accès de lecture pour la ressource Amazon S3 `nyc-t1c/*`.
 - Autorisations du niveau d'accès d'écriture pour la ressource Amazon S3 `yourBucketName/*`.
 - Lorsque vous sélectionnez le nom de la politique *YourPolicyName*, prenez-en note, auquel vous vous référerez ultérieurement.
2. Créez un rôle pour votre tâche AWS Glue for Ray en suivant les étapes décrites dans la section [Création d'un rôle pour un AWS service \(console\)](#) dans le guide de l'utilisateur IAM.
 - Lorsque vous sélectionnez une entité AWS de service fiable, choisissez Glue. Cela renseignera automatiquement la relation de confiance nécessaire pour votre tâche.
 - Lorsque vous sélectionnez des politiques pour la politique d'autorisations, joignez les politiques suivantes :
 - `AWSGlueServiceRole`
 - *YourPolicyName*
 - Lorsque vous sélectionnez le nom du rôle, prenez-en note *YourRoleName*, auquel vous vous référerez dans les étapes ultérieures.

Étape 3 : créer et exécuter une tâche AWS Glue pour Ray

Au cours de cette étape, vous créez une AWS Glue tâche à l'aide du AWS Management Console, vous lui fournissez un exemple de script et vous exécutez la tâche. Lorsque vous créez une tâche, elle crée un emplacement dans la console où vous pouvez stocker, configurer et modifier votre script Ray. Pour plus d'informations sur la création de tâches, consultez [the section called “Se connecter à la console”](#).

Dans ce didacticiel, nous abordons le scénario ETL suivant : vous souhaitez lire les enregistrements de janvier 2022 du jeu de données New York City TLC Trip Record, ajouter une nouvelle colonne (`tip_rate`) au jeu de données en combinant les données dans des colonnes existantes, puis supprimer un certain nombre de colonnes qui ne sont pas pertinentes pour votre analyse actuelle, puis vous souhaitez y écrire les résultats. *yourBucketName* Le script Ray suivant exécute les étapes suivantes :

```
import ray
import pandas
from ray import data

ray.init('auto')

ds = ray.data.read_csv("s3://nyc-tlc/opendata_repo/opendata_webconvert/yellow/
yellow_tripdata_2022-01.csv")

# Add the given new column to the dataset and show the sample record after adding a new
column
ds = ds.add_column( "tip_rate", lambda df: df["tip_amount"] / df["total_amount"])

# Dropping few columns from the underlying Dataset
ds = ds.drop_columns(["payment_type", "fare_amount", "extra", "tolls_amount",
"improvement_surcharge"])

ds.write_parquet("s3://yourBucketName/ray/tutorial/output/")
```

Pour créer et exécuter une tâche AWS Glue pour Ray

1. Dans le AWS Management Console, accédez à la page de AWS Glue destination.
2. Dans le volet de navigation latéral, choisissez Tâches ETL.
3. Dans Créer une tâche, choisissez Éditeur de script Ray, puis choisissez Créer, comme dans l'illustration suivante.

AWS Glue Studio [Info](#)

Create job [Info](#)

[Create](#)

☐ Visual with a source and target
Start with a source, ApplyMapping transform, and target.

☐ Visual with a blank canvas
Author using an interactive visual interface.

☐ Spark script editor
Write or upload your own Spark code.

☐ Python Shell script editor
Write or upload your own Python shell script.

☐ Jupyter Notebook
Write your own code in a Jupyter Notebook for interactive development.

☒ Ray script editor
Write your own code to run on Ray.

Options [Info](#)

- ☒ Create a new script with boilerplate code
- ☐ Upload and edit an existing script
Choose a local file.

- Collez le texte complet du script dans le volet Script et remplacez le texte existant.
- Accédez aux détails du Job et définissez la propriété IAM Role sur **YourRoleName**.
- Choisissez Enregistrer, puis Exécuter.

Étape 4 : inspecter votre sortie

Après avoir exécuté votre AWS Glue tâche, vous devez vérifier que le résultat correspond aux attentes de ce scénario. Pour ce faire, suivez la procédure suivante.

Pour valider si votre tâche Ray a été exécutée correctement

- Sur la page des détails de la tâche, accédez à Exécutions.
- Au bout de quelques minutes, vous devriez voir une exécution dont le statut d'exécution est Réussi.
- Accédez à la console Amazon S3 à l'adresse <https://console.aws.amazon.com/s3/> et inspectez-la **yourBucketName**. Vous devez voir des fichiers écrits dans votre compartiment de sortie.
- Lisez les fichiers Parquet et vérifiez leur contenu. Vous pouvez le faire avec vos outils existants. Si vous n'avez pas de processus de validation des fichiers Parquet, vous pouvez le faire dans la AWS Glue console avec une session AWS Glue interactive, en utilisant Spark ou Ray (en version préliminaire).

Dans une session interactive, vous avez accès aux bibliothèques Ray Data, Spark ou Pandas, qui sont fournies par défaut (en fonction du moteur que vous avez choisi). Pour

vérifier le contenu de votre fichier, vous pouvez utiliser les méthodes d'inspection courantes disponibles dans ces bibliothèques (des méthodes comme `count`, `schema` et `show`). Pour plus d'informations sur les sessions interactives dans la console, consultez la section [Utilisation de blocs-notes avec AWS Blue Studio et AWS Glue](#).

Comme vous avez confirmé que les fichiers ont été écrits dans le compartiment, vous pouvez affirmer avec une relative certitude que si votre sortie présente des problèmes, ils ne sont pas liés à la configuration IAM. Configurez votre session `yourRoleName` pour avoir accès aux fichiers concernés.

Si vous n'obtenez pas les résultats escomptés, consultez le contenu de dépannage de ce guide pour identifier la source de l'erreur et y remédier. Pour interpréter les statuts d'erreur d'exécution des tâches, consultez [the section called “Statuts d'exécution de la tâche”](#). Vous trouverez le contenu de dépannage dans le chapitre [Résolution des problèmes AWS Glue](#). Pour les erreurs spécifiques liées aux tâches Ray, consultez [the section called “Dépannage des erreurs Ray”](#) au chapitre de dépannage.

Étapes suivantes

Vous avez maintenant vu et exécuté un processus ETL utilisant AWS Glue for Ray de bout en bout. Vous pouvez utiliser les ressources suivantes pour comprendre AWS Glue les outils fournis par Ray pour transformer et interpréter vos données à grande échelle.

- Pour plus d'informations sur le modèle de tâche de Ray, consultez [the section called “Utiliser Ray Core et Ray Data AWS Glue pour Ray”](#). Pour plus d'expérience dans l'utilisation des tâches Ray, suivez les exemples de la documentation Ray Core. Consultez [Ray Core: Ray Tutorials and Examples \(2.4.0\)](#) dans la documentation Ray.
- Pour obtenir des conseils sur les bibliothèques de gestion de données disponibles dans AWS Glue for Ray, consultez [the section called “Connexion aux données”](#). Pour en savoir plus sur l'utilisation de Ray Data pour transformer et écrire des jeux de données, suivez les exemples de la documentation Ray Data. Consultez [Ray Data: Examples \(2.4.0\)](#).
- Pour plus d'informations sur la configuration AWS Glue des tâches Ray, consultez [the section called “Utilisation des tâches Ray”](#).
- Pour plus d'informations sur l'écriture de scripts AWS Glue pour Ray, continuez à lire la documentation de cette section.

Utiliser Ray Core et Ray Data AWS Glue pour Ray

Ray est un cadre permettant d'augmenter les scripts Python en répartissant le travail sur un cluster. Vous pouvez utiliser Ray comme solution à de nombreux types de problèmes. Ray fournit donc des bibliothèques pour optimiser certaines tâches. Dans AWS Glue, nous nous concentrons sur l'utilisation de Ray pour transformer de grands ensembles de données. AWS Glue propose un support pour Ray Data et certaines parties de Ray Core afin de faciliter cette tâche.

Qu'est-ce que Ray Core ?

La première étape de la création d'une application distribuée consiste à identifier et à définir le travail pouvant être effectué simultanément. Ray Core contient les parties de Ray que vous utilisez pour définir les tâches qui peuvent être effectuées simultanément. Ray fournit des informations de référence et de démarrage rapide que vous pouvez utiliser pour découvrir les outils qu'ils fournissent. Pour plus d'informations, consultez [Qu'est-ce que Ray Core ?](#) et [Ray Core Quick Start](#). Pour plus d'informations sur la définition efficace des tâches simultanées dans Ray, consultez [Tips for first-time users](#).

Tâches et acteurs Ray

Dans AWS Glue la documentation de Ray, nous pouvons faire référence aux tâches et aux acteurs, qui sont des concepts fondamentaux de Ray.

Ray utilise les fonctions et les classes Python comme éléments de base d'un système informatique distribué. Tout comme lorsque les fonctions et les variables Python deviennent des « méthodes » et des « attributs » lorsqu'elles sont utilisées dans une classe, les fonctions deviennent des « tâches » et les classes deviennent des « acteurs » lorsqu'elles sont utilisées dans Ray pour envoyer du code aux travailleurs. Vous pouvez identifier les fonctions et les classes susceptibles d'être utilisées par Ray grâce à l'annotation `@ray.remote`.

Les tâches et les acteurs sont configurables, ont un cycle de vie et utilisent des ressources de calcul tout au long de leur cycle de vie. Le code qui génère des erreurs peut être retracé jusqu'à une tâche ou à un acteur lorsque vous trouvez la cause première des problèmes. Ces termes peuvent donc apparaître lorsque vous apprenez à configurer, surveiller ou déboguer AWS Glue des tâches Ray.

Pour commencer à apprendre à utiliser efficacement les tâches et les acteurs pour créer une application distribuée, consultez [Key Concepts](#) dans la documentation Ray.

Ray Core va AWS Glue remplacer Ray

AWS Glue les environnements for Ray gèrent la formation et le dimensionnement des clusters, ainsi que la collecte et la visualisation des journaux. Parce que nous gérons ces problèmes, nous limitons par conséquent l'accès et le support APIs au cœur intégré qui serait utilisé pour résoudre ces problèmes dans un cluster open source.

Dans l'environnement d'exécution Ray2.4 géré, nous ne prenons pas en charge :

- [CLI Ray Core](#)
- [CLI Ray State](#)
- Les méthodes de l'utilitaire métrique `ray.util.metrics` Prometheus :
 - [Compteur](#)
 - [Jauge](#)
 - [Histogramme](#)
- Autres outils de débogage :
 - [ray.util.pdb.set_trace](#)
 - [ray.util.inspect_serializability](#)
 - [ray.timeline](#)

Qu'est-ce que Ray Data ?

Lorsque vous vous connectez à des sources de données et à des destinations, que vous manipulez des jeux de données et que vous initiez des transformations courantes, Ray Data est une méthodologie simple qui permet d'utiliser Ray pour résoudre les problèmes de transformation des jeux de données Ray. Pour plus d'informations sur l'utilisation de Ray Data, consultez [Ray Datasets: Distributed Data Preprocessing](#).

Vous pouvez utiliser Ray Data ou d'autres outils pour accéder à vos données. Pour plus d'informations sur l'accès à vos données dans Ray, consultez [the section called “Connexion aux données”](#).

Ray Data à la AWS Glue place de Ray

Ray Data est pris en charge et fourni par défaut dans l'environnement d'exécution géré Ray2.4. Pour plus d'informations sur les modules fournis, consultez [the section called “Modules fournis avec les tâches Ray”](#).

Fournir des fichiers et des bibliothèques Python aux tâches Ray

Cette section fournit les informations dont vous avez besoin pour utiliser les bibliothèques Python avec les tâches AWS Glue Ray. Vous pouvez utiliser certaines bibliothèques communes incluses par défaut dans toutes les tâches Ray. Vous pouvez également fournir vos propres bibliothèques Python à votre tâche Ray.

Modules fournis avec les tâches Ray

Vous pouvez exécuter des flux de travail d'intégration de données dans une tâche Ray à l'aide des packages fournis suivants. Ces packages sont disponibles par défaut dans les tâches Ray.

AWS Glue version 4.0

Dans la AWS Glue version 4.0, l'environnement Ray (Ray2.4runtime) fournit les packages suivants :

- boto3 == 1.26.133
- ray == 2.4.0
- pyarrow == 11.0.0
- pandas == 1.5.3
- numpy == 1.24.3
- fsspec == 2023.4.0

Cette liste inclut tous les packages qui seront installés avec `ray[data] == 2.4.0`. Ray Data est prêt à l'emploi.

Fournir des fichiers à votre tâche Ray

Vous pouvez fournir des fichiers à votre tâche Ray avec le paramètre `--working-dir`. Fournissez à ce paramètre un chemin d'accès à un fichier .zip hébergé sur Amazon S3. Dans le fichier .zip, vos fichiers doivent être contenus dans un seul répertoire de premier niveau. Aucun autre fichier ne doit se trouver au niveau supérieur.

Vos fichiers sont distribués à chaque nœud Ray avant que votre script ne commence à s'exécuter. Réfléchissez à l'impact que cela peut avoir sur l'espace disque disponible pour chaque nœud Ray. L'espace disque disponible est déterminé par le WorkerType ensemble défini dans la configuration de

la tâche. Si vous souhaitez fournir vos données de tâche à grande échelle, ce mécanisme n'est pas la bonne solution. Pour plus d'informations sur la fourniture de données à votre tâche, consultez [the section called “Connexion aux données”](#).

Vos fichiers seront accessibles comme si le répertoire avait été fourni à Ray via le paramètre `working_dir`. Par exemple, pour lire un fichier nommé `sample.txt` dans le répertoire de premier niveau de votre fichier `.zip`, vous pouvez appeler :

```
@ray.remote
def do_work():
    f = open("sample.txt", "r")
    print(f.read())
```

Pour plus d'informations sur `working_dir`, consultez [Ray documentation](#). Cette fonctionnalité se comporte de la même manière que les fonctionnalités natives de Ray.

Modules Python supplémentaires pour les tâches Ray

Modules supplémentaires de PyPI

Les tâches Ray utilisent Python Package Installer (pip3) pour installer les modules supplémentaires qui seront utilisés par un script Ray. Vous pouvez utiliser le paramètre `--pip-install` avec une liste de modules Python séparés par des virgules pour ajouter un nouveau module ou modifier la version d'un module existant.

Par exemple, pour mettre à jour ou ajouter un nouveau module `scikit-learn`, utilisez la paire clé-valeur suivante :

```
"--pip-install", "scikit-learn==0.21.3"
```

Si vous avez des modules ou des correctifs personnalisés, vous pouvez distribuer vos propres bibliothèques depuis Amazon S3 avec le paramètre `--s3-py-modules`. Avant de charger votre distribution, il peut être nécessaire de la reconditionner et de la recréer. Suivez les lignes directrices indiquées dans [the section called “Inclure du code Python dans les tâches Ray”](#).

Distributions personnalisées depuis Amazon S3

Les distributions personnalisées doivent respecter les directives d'emballage de Ray en ce qui concerne les dépendances. La section suivante explique comment créer ces distributions. Pour plus d'informations sur la façon dont Ray configure les dépendances, consultez [Environment Dependencies](#) (Dépendances d'environnement) dans la documentation Ray.

Pour inclure un élément distribuable personnalisé après avoir évalué son contenu, chargez votre élément distribuable dans un compartiment disponible pour le rôle IAM de la tâche. Indiquez le chemin Amazon S3 vers une archive zip Python dans la configuration de vos paramètres. Si vous fournissez plusieurs éléments distribuables, séparez-les par des virgules. Par exemple :

```
"--s3-py-modules", "s3://s3bucket/pythonPackage.zip"
```

Limites

Les tâches Ray ne prennent pas en charge la compilation de code natif dans l'environnement de la tâche. Cela peut vous limiter si vos dépendances Python dépendent de manière transitive du code compilé natif. Les tâches Ray peuvent exécuter les fichiers binaires fournis, mais ils doivent être compilés pour Linux sur ARM64. Vous pourrez ainsi peut-être utiliser le contenu des roues `aarch64manylinux`. Vous pouvez fournir vos dépendances natives dans un format compilé en reconditionnant une roue selon les normes Ray. Cela implique généralement de supprimer des dossiers `dist-info` pour ne laisser qu'un seul dossier à la racine de l'archive.

Vous ne pouvez pas mettre à niveau la version de `ray` ou de `ray[data]` en utilisant ce paramètre. Pour utiliser une nouvelle version de Ray, vous devrez modifier le champ d'exécution de votre tâche, une fois que nous aurons mis en place la prise en charge de cette version. Pour de plus amples informations sur les versions de Ray pris en charge, consultez [the section called “AWS Glue versions”](#).

Inclure du code Python dans les tâches Ray

La Python Software Foundation propose des comportements standardisés pour l'empaquetage de fichiers Python destinés à être utilisés avec différents environnements d'exécution. Ray introduit des limites que vous devez connaître en matière de normes d'empaquetage. AWS Glue ne spécifie pas de normes d'empaquetage autres que celles spécifiées à Ray. Les instructions suivantes fournissent des conseils standards sur l'empaquetage de packages Python simples.

Empaquetez vos fichiers dans une archive `.zip`. Un répertoire doit se trouver à la racine de l'archive. Il ne doit pas y avoir d'autres fichiers au niveau de la racine de l'archive, sous peine de provoquer un comportement inattendu. Le répertoire racine est le package, et son nom est utilisé pour faire référence à votre code Python lorsque vous l'importez.

Si vous fournissez une distribution sous cette forme à une tâche Ray avec `--s3-py-modules`, vous pourrez importer du code Python depuis votre package dans votre script Ray.

Votre package peut fournir un seul module Python avec des fichiers Python, ou vous pouvez regrouper plusieurs modules. Lorsque vous reconditionnez des dépendances, telles que les bibliothèques de PyPI, vérifiez la présence de fichiers cachés et de répertoires de métadonnées dans ces packages.

 Warning

Certains comportements du système d'exploitation font qu'il est difficile de suivre correctement ces instructions d'emballage.

- OSX peut ajouter des fichiers cachés tels que `__MACOSX` à votre fichier zip au niveau supérieur.
- Windows peut ajouter automatiquement vos fichiers à un dossier à l'intérieur du fichier zip, créant ainsi involontairement un dossier imbriqué.

Les procédures suivantes supposent que vous interagissez avec vos fichiers sous Amazon Linux 2 ou un système d'exploitation similaire qui fournit une distribution des utilitaires Info-ZIP `zip` et `zipinfo`. Nous vous recommandons d'utiliser ces outils pour éviter les comportements inattendus.

Pour emballer des fichiers Python à utiliser dans Ray

1. Créez un répertoire temporaire avec le nom de votre package, puis confirmez que votre répertoire de travail est son répertoire parent. Vous pouvez le faire à l'aide des commandes suivantes :

```
cd parent_directory
mkdir temp_dir
```

2. Copiez vos fichiers dans le répertoire temporaire, puis confirmez la structure de votre répertoire. Le contenu de ce répertoire sera directement accessible en tant que module Python. Vous pouvez le faire à l'aide de la commande suivante :

```
ls -AR temp_dir
# my_file_1.py
# my_file_2.py
```

3. Compressez votre dossier temporaire en utilisant `zip`. Vous pouvez le faire à l'aide des commandes suivantes :

```
zip -r zip_file.zip temp_dir
```

4. Vérifiez que votre fichier est correctement emballé. *zip_file.zip* doit maintenant se trouver dans votre répertoire de travail. Vous pouvez l'inspecter avec la commande suivante :

```
zipinfo -l zip_file.zip  
# temp_dir/  
# temp_dir/my_file_1.py  
# temp_dir/my_file_2.py
```

Pour reconditionner un package Python à utiliser dans Ray.

1. Créez un répertoire temporaire avec le nom de votre package, puis confirmez que votre répertoire de travail est son répertoire parent. Vous pouvez le faire à l'aide des commandes suivantes :

```
cd parent_directory  
mkdir temp_dir
```

2. Décompressez votre package et copiez-en le contenu dans votre répertoire temporaire. Supprimez les fichiers liés à votre ancienne norme d'emballage, en ne laissant que le contenu du module. Vérifiez que la structure de votre fichier semble correcte à l'aide de la commande suivante :

```
ls -AR temp_dir  
# my_module  
# my_module/__init__.py  
# my_module/my_file_1.py  
# my_module/my_submodule/__init__.py  
# my_module/my_submodule/my_file_2.py  
# my_module/my_submodule/my_file_3.py
```

3. Comprimez votre dossier temporaire en utilisant zip. Vous pouvez le faire à l'aide des commandes suivantes :

```
zip -r zip_file.zip temp_dir
```

4. Vérifiez que votre fichier est correctement empaqueté. `zip_file.zip` doit maintenant se trouver dans votre répertoire de travail. Vous pouvez l'inspecter avec la commande suivante :

```
zipinfo -l zip_file.zip
# temp_dir/my_module/
# temp_dir/my_module/__init__.py
# temp_dir/my_module/my_file_1.py
# temp_dir/my_module/my_submodule/
# temp_dir/my_module/my_submodule/__init__.py
# temp_dir/my_module/my_submodule/my_file_2.py
# temp_dir/my_module/my_submodule/my_file_3.py
```

Connexion aux données dans les tâches Ray

AWS Glue Ray Jobs peut utiliser un large éventail de packages Python conçus pour vous permettre d'intégrer rapidement des données. Nous fournissons un ensemble minimal de dépendances afin de ne pas encombrer votre environnement. Pour plus d'informations sur ce qui est inclus par défaut, consultez [the section called “Modules fournis avec les tâches Ray”](#).

Note

AWS Glue extract, transform, and load (ETL) fournit l' `DynamicFrame` abstraction nécessaire pour rationaliser les flux de travail ETL dans lesquels vous résolvez les différences de schéma entre les lignes de votre ensemble de données. AWS Glue L'ETL fournit des fonctionnalités supplémentaires : signets de tâches et regroupement de fichiers d'entrée. Actuellement, nous ne proposons pas de fonctionnalités correspondantes dans les tâches Ray.

AWS Glue for Spark fournit un support direct pour la connexion à certains formats de données, sources et récepteurs. Dans Ray, le kit AWS SDK pour Pandas et les bibliothèques tierces actuelles répondent en grande partie à ce besoin. Vous devrez consulter ces bibliothèques pour connaître les fonctionnalités disponibles.

AWS Glue pour Ray, l'intégration avec Amazon VPC n'est pas disponible actuellement. Les ressources d'un Amazon VPC ne seront pas accessibles sans routage public. Pour plus d'informations sur l'utilisation AWS Glue avec Amazon VPC, consultez. [the section called “Configuration des points de terminaison VPC de l'interface \(\) pour AWS PrivateLinkAWS Glue ”](#)

Bibliothèques communes pour travailler avec des données dans Ray

Ray Data : Ray Data fournit des méthodes pour gérer les formats de données, les sources et les récepteurs courants. Pour plus d'informations sur les formats et les sources pris en charge dans Ray Data, consultez [Input/Output](#) dans la documentation Ray Data. Ray Data est une bibliothèque d'opinion, plutôt qu'une bibliothèque générale, destinée à manipuler des jeux de données.

Ray fournit des conseils sur les cas d'utilisation où Ray Data pourrait être la meilleure solution pour votre tâche. Pour plus d'informations, consultez les [cas d'utilisation de Ray](#) dans la documentation Ray.

AWS SDK pour pandas (awswrangler) — Le AWS SDK pour pandas est un AWS produit qui fournit des solutions propres et testées pour la lecture et l'écriture vers des AWS services lorsque vos transformations gèrent des données avec des pandas. DataFrames Pour plus d'informations sur les formats et les sources pris en charge dans le AWS SDK pour pandas, consultez la [référence d'API](#) dans la documentation du AWS SDK pour pandas.

Pour des exemples de lecture et d'écriture de données avec le AWS SDK pour pandas, voir [Quick Start](#) dans la documentation du AWS SDK pour pandas. Le AWS SDK pour pandas ne fournit pas de transformations pour vos données. Il fournit uniquement une prise en charge pour la lecture et l'écriture à partir de sources.

Modin : Modin est une bibliothèque Python qui implémente les opérations Pandas courantes de manière distribuée. Pour plus d'informations sur Modin, consultez [Modin documentation](#). Modin lui-même ne fournit pas de prise en charge de la lecture et de l'écriture à partir de sources. Il fournit des implémentations distribuées de transformations courantes. Modin est supporté par le AWS SDK pour pandas.

Lorsque vous exécutez Modin et le AWS SDK pour pandas ensemble dans un environnement Ray, vous pouvez effectuer des tâches ETL courantes avec des résultats performants. Pour plus d'informations sur l'utilisation de Modin avec le AWS SDK pour pandas, voir [At scale](#) dans la documentation du AWS SDK pour pandas.

Autres frameworks — Pour plus d'informations sur les frameworks pris en charge par Ray, consultez [The Ray Ecosystem](#) dans la documentation Ray. Nous ne prenons pas en charge les autres frameworks AWS Glue de Ray.

Connexion aux données via le catalogue de données

La gestion de vos données via le catalogue de données en conjonction avec les tâches Ray est prise en charge par le AWS SDK pour pandas. Pour plus d'informations, consultez [Glue Catalog](#) sur le site AWS Web du SDK pour pandas.

Utilisation de ce service avec un AWS SDK

AWS des kits de développement logiciel (SDKs) sont disponibles pour de nombreux langages de programmation courants. Chaque SDK fournit une API, des exemples de code et de la documentation qui facilitent la création d'applications par les développeurs dans leur langage préféré.

Documentation SDK	Exemples de code
AWS SDK pour C++	AWS SDK pour C++ exemples de code
AWS CLI	AWS CLI exemples de code
AWS SDK pour Go	AWS SDK pour Go exemples de code
AWS SDK pour Java	AWS SDK pour Java exemples de code
AWS SDK pour JavaScript	AWS SDK pour JavaScript exemples de code
AWS SDK pour Kotlin	AWS SDK pour Kotlin exemples de code
AWS SDK pour .NET	AWS SDK pour .NET exemples de code
AWS SDK pour PHP	AWS SDK pour PHP exemples de code
Outils AWS pour PowerShell	Outils AWS pour PowerShell exemples de code
AWS SDK pour Python (Boto3)	AWS SDK pour Python (Boto3) exemples de code
AWS SDK pour Ruby	AWS SDK pour Ruby exemples de code
Kit AWS SDK pour Rust	Kit AWS SDK pour Rust exemples de code
AWS SDK pour SAP ABAP	AWS SDK pour SAP ABAP exemples de code
Kit AWS SDK pour Swift	Kit AWS SDK pour Swift exemples de code

Pour voir des exemples spécifiques à ce service, consultez [AWS Glue Exemples de code d'API utilisant AWS SDKs](#).

 Exemple de disponibilité

Vous n'avez pas trouvé ce dont vous avez besoin ? Demandez un exemple de code en utilisant le lien [Provide feedback](#) (Fournir un commentaire) en bas de cette page.

AWS Glue API

Cette section décrit les types de données et les primitives utilisés par AWS Glue SDKs et Tools. Il existe trois méthodes générales d'interaction AWS Glue programmatique en dehors du AWS Management Console, chacune avec sa propre documentation :

- Les bibliothèques SDK linguistiques vous permettent d'accéder aux ressources AWS provenant de langages de programmation courants. Pour plus d'informations, consultez [Outils pour créer sur AWS](#).
- Vous AWS CLI permet d'accéder aux AWS ressources depuis la ligne de commande. Pour plus d'informations, consultez [Référence des commandes AWS CLI](#).
- AWS CloudFormation vous permet de définir un ensemble de AWS ressources à provisionner ensemble de manière cohérente. Pour plus d'informations, consultez [AWS CloudFormation: référence AWS Glue des types de ressources](#).

Cette section documente les primitives partagées indépendamment de celles-ci SDKs et des outils. Les outils utilisent le [AWS Glue Web API Reference](#) pour communiquer avec AWS.

Table des matières

- [Sécurité APIs dans AWS Glue](#)
 - [Types de données](#)
 - [DataCatalogEncryptionSettings structure](#)
 - [EncryptionAtRest structure](#)
 - [ConnectionPasswordEncryption structure](#)
 - [EncryptionConfiguration structure](#)
 - [Structure S3Encryption](#)
 - [CloudWatchEncryption structure](#)
 - [JobBookmarksEncryption structure](#)
 - [SecurityConfiguration structure](#)
 - [GluePolicy structure](#)
 - [DataQualityEncryption structure](#)
 - [Opérations](#)
 - [GetDataCatalogEncryptionSettings action \(Python : `get\_data\_catalog\_encryption\_settings`\)](#)

- [PutDataCatalogEncryptionSettings action \(Python : put_data_catalog_encryption_settings\)](#)
- [PutResourcePolicy action \(Python : put_resource_policy\)](#)
- [GetResourcePolicy action \(Python : get_resource_policy\)](#)
- [DeleteResourcePolicy action \(Python : delete_resource_policy\)](#)
- [CreateSecurityConfiguration action \(Python : create_security_configuration\)](#)
- [DeleteSecurityConfiguration action \(Python : delete_security_configuration\)](#)
- [GetSecurityConfiguration action \(Python : get_security_configuration\)](#)
- [GetSecurityConfigurations action \(Python : get_security_configurations\)](#)
- [GetResourcePolicies action \(Python : get_resource_policies\)](#)
- [API d'objets de catalogue](#)
 - [API de catalogues](#)
 - [Types de données](#)
 - [Structure du catalogue](#)
 - [CatalogInput structure](#)
 - [TargetRedshiftCatalog structure](#)
 - [CatalogProperties structure](#)
 - [CatalogPropertiesOutput structure](#)
 - [DataLakeAccessProperties structure](#)
 - [DataLakeAccessPropertiesOutput structure](#)
 - [FederatedCatalog structure](#)
 - [Opérations](#)
 - [CreateCatalog action \(Python : create_catalog\)](#)
 - [UpdateCatalog action \(Python : update_catalog\)](#)
 - [DeleteCatalog action \(Python : supprimer_catalogue\)](#)
 - [GetCatalog action \(Python : get_catalog\)](#)
 - [GetCatalogs action \(Python : get_catalogs\)](#)
 - [API d'une base de données](#)
 - [Types de données](#)
 - [Structure Database](#)
 - [DatabaseInput structure](#)

- [PrincipalPermissions structure](#)
- [DataLakePrincipal structure](#)
- [Databaseldentifier structure](#)
- [FederatedDatabase structure](#)
- [Opérations](#)
- [CreateDatabase action \(Python : créer_base de données\)](#)
- [UpdateDatabase action \(Python : update_database\)](#)
- [DeleteDatabase action \(Python : supprimer_base de données\)](#)
- [GetDatabase action \(Python : get_database\)](#)
- [GetDatabases action \(Python : get_databases\)](#)
- [API de table](#)
 - [Types de données](#)
 - [Structure de table](#)
 - [TableInput structure](#)
 - [FederatedTable structure](#)
 - [Structure de colonne](#)
 - [StorageDescriptor structure](#)
 - [SchemaReference structure](#)
 - [SerDeInfo structure](#)
 - [Structure de tri](#)
 - [SkewedInfo structure](#)
 - [TableVersion structure](#)
 - [TableError structure](#)
 - [TableVersionError structure](#)
 - [SortCriterion structure](#)
 - [TableIdentifier structure](#)
 - [KeySchemaElement structure](#)
 - [PartitionIndex structure](#)
 - [PartitionIndexDescriptor structure](#)
 - [BackfillError structure](#)

- [IcebergInput structure](#)
- [OpenTableFormatInput structure](#)
- [ViewDefinition structure](#)
- [ViewDefinitionInput structure](#)
- [ViewRepresentation structure](#)
- [ViewRepresentationInput structure](#)
- [UpdateOpenTableFormatInput structure](#)
- [UpdateIcebergInput structure](#)
- [CreateIcebergTableInput structure](#)
- [UpdateIcebergTableInput structure](#)
- [IcebergSortOrder structure](#)
- [IcebergSortField structure](#)
- [IcebergPartitionSpec structure](#)
- [IcebergPartitionField structure](#)
- [IcebergSchema structure](#)
- [IcebergStructField structure](#)
- [IcebergTableUpdate structure](#)
- [Opérations](#)
- [CreateTable action \(Python : créer_table\)](#)
- [UpdateTable action \(Python : update_table\)](#)
- [DeleteTable action \(Python : supprimer_table\)](#)
- [BatchDeleteTable action \(Python : batch_delete_table\)](#)
- [GetTable action \(Python : get_table\)](#)
- [GetTables action \(Python : get_tables\)](#)
- [GetTableVersion action \(Python : get_table_version\)](#)
- [GetTableVersions action \(Python : get_table_versions\)](#)
- [DeleteTableVersion action \(Python : supprimer_table_version\)](#)
- [BatchDeleteTableVersion action \(Python : batch_delete_table_version\)](#)
- [SearchTables action \(Python : tables de recherche\)](#)
- [GetPartitionIndexes action \(Python : get_partition_indexes\)](#)

- [CreatePartitionIndex action \(Python : create_partition_index\)](#)
- [DeletePartitionIndex action \(Python : delete_partition_index\)](#)
- [GetColumnStatisticsForTable action \(Python : get_column_statistics_for_table\)](#)
- [UpdateColumnStatisticsForTable action \(Python : update_column_statistics_for_table\)](#)
- [DeleteColumnStatisticsForTable action \(Python : delete_column_statistics_for_table\)](#)
- [API de partition](#)
 - [Types de données](#)
 - [Structure de partition](#)
 - [PartitionInput structure](#)
 - [PartitionSpecWithSharedStorageDescriptor structure](#)
 - [PartitionListComposingSpec structure](#)
 - [PartitionSpecProxy structure](#)
 - [PartitionValueList structure](#)
 - [Structure d'un segment](#)
 - [PartitionError structure](#)
 - [BatchUpdatePartitionFailureEntry structure](#)
 - [BatchUpdatePartitionRequestEntry structure](#)
 - [StorageDescriptor structure](#)
 - [SchemaReference structure](#)
 - [SerDeInfo structure](#)
 - [SkewedInfo structure](#)
 - [Opérations](#)
 - [CreatePartition action \(Python : créer_partition\)](#)
 - [BatchCreatePartition action \(Python : batch_create_partition\)](#)
 - [UpdatePartition action \(Python : update_partition\)](#)
 - [DeletePartition action \(Python : supprimer_partition\)](#)
 - [BatchDeletePartition action \(Python : batch_supprimer_partition\)](#)
 - [GetPartition action \(Python : get_partition\)](#)
 - [GetPartitions action \(Python : get_partitions\)](#)
 - [BatchGetPartition action \(Python : batch_get_partition\)](#)

- [BatchUpdatePartition action \(Python : batch_update_partition\)](#)
- [GetColumnStatisticsForPartition action \(Python : get_column_statistics_for_partition\)](#)
- [UpdateColumnStatisticsForPartition action \(Python : update_column_statistics_for_partition\)](#)
- [DeleteColumnStatisticsForPartition action \(Python : supprimer_column_statistics_for_partition\)](#)
- [API de connexions](#)
 - [API de connexion](#)
 - [Types de données](#)
 - [Structure de connexion](#)
 - [ConnectionInput structure](#)
 - [TestConnectionInput structure](#)
 - [PhysicalConnectionRequirements structure](#)
 - [GetConnectionsFilter structure](#)
 - [AuthenticationConfiguration structure](#)
 - [AuthenticationConfigurationInput structure](#)
 - [OAuth2Structure des propriétés](#)
 - [OAuth2PropertiesInput structure](#)
 - [OAuth2ClientApplication structure](#)
 - [AuthorizationCodeProperties structure](#)
 - [BasicAuthenticationCredentials structure](#)
 - [OAuth2Structure des informations d'identification](#)
 - [Opérations](#)
 - [CreateConnection action \(Python : créer_connexion\)](#)
 - [DeleteConnection action \(Python : supprimer_connexion\)](#)
 - [GetConnection action \(Python : get_connection\)](#)
 - [GetConnections action \(Python : get_connections\)](#)
 - [UpdateConnection action \(Python : update_connection\)](#)
 - [TestConnection action \(Python : test_connection\)](#)
 - [BatchDeleteConnection action \(Python : batch_delete_connection\)](#)
 - [API des types de connexion](#)

- [Gestion des connexions APIs](#)
- [DescribeConnectionType action \(Python : describe_connection_type\)](#)
- [ListConnectionTypes action \(Python : list_connection_types\)](#)
- [ConnectionTypeBrief structure](#)
- [ConnectionTypeVariant structure](#)
- [types de données](#)
- [Structure de validation](#)
- [AuthConfiguration structure](#)
- [Structure des capacités](#)
- [Structure de la propriété](#)
- [AllowedValue structure](#)
- [ComputeEnvironmentConfiguration structure](#)
- [Métadonnées de connexion et API de prévisualisation](#)
 - [Types de données](#)
 - [Structure de l'entité](#)
 - [Structure du champ](#)
 - [Opérations](#)
 - [ListEntities action \(Python : list_entities\)](#)
 - [DescribeEntity action \(Python : describe_entity\)](#)
 - [GetEntityRecords action \(Python : get_entity_records\)](#)
- [API de fonction définie par l'utilisateur](#)
 - [Types de données](#)
 - [UserDefinedFunction structure](#)
 - [UserDefinedFunctionInput structure](#)
 - [Opérations](#)
 - [CreateUserDefinedFunction action \(Python : create_user_defined_function\)](#)
 - [UpdateUserDefinedFunction action \(Python : update_user_defined_function\)](#)
 - [DeleteUserDefinedFunction action \(Python : delete_user_defined_function\)](#)
 - [GetUserDefinedFunction action \(Python : get_user_defined_function\)](#)
 - [GetUserDefinedFunctions action \(Python : get_user_defined_functions\)](#)

- [Importation d'un Athena catalogue dans AWS Glue](#)
 - [Types de données](#)
 - [CatalogImportStatus structure](#)
 - [Opérations](#)
 - [ImportCatalogToGlue action \(Python : import_catalog_to_glue\)](#)
 - [GetCatalogImportStatus action \(Python : get_catalog_import_status\)](#)
- [API d'optimiseur de table](#)
 - [Types de données](#)
 - [TableOptimizer structure](#)
 - [TableOptimizerConfiguration structure](#)
 - [TableOptimizerVpcConfiguration structure](#)
 - [CompactionConfiguration structure](#)
 - [IcebergCompactionConfiguration structure](#)
 - [TableOptimizerRun structure](#)
 - [BatchGetTableOptimizerEntry structure](#)
 - [BatchTableOptimizer structure](#)
 - [BatchGetTableOptimizerError structure](#)
 - [RetentionConfiguration structure](#)
 - [IcebergRetentionConfiguration structure](#)
 - [OrphanFileDeletionConfiguration structure](#)
 - [IcebergOrphanFileDeletionConfiguration structure](#)
 - [CompactionMetrics structure](#)
 - [RetentionMetrics structure](#)
 - [OrphanFileDeletionMetrics structure](#)
 - [IcebergCompactionMetrics structure](#)
 - [IcebergRetentionMetrics structure](#)
 - [IcebergOrphanFileDeletionMetrics structure](#)
 - [RunMetrics structure](#)
 - [Opérations](#)
 - [GetTableOptimizer action \(Python : get_table_optimizer\)](#)

- [BatchGetTableOptimizer action \(Python : batch_get_table_optimizer\)](#)
- [ListTableOptimizerRuns action \(Python : list_table_optimizer_runs\)](#)
- [CreateTableOptimizer action \(Python : create_table_optimizer\)](#)
- [DeleteTableOptimizer action \(Python : delete_table_optimizer\)](#)
- [UpdateTableOptimizer action \(Python : update_table_optimizer\)](#)
- [API de classifieurs et d'crawlers](#)
 - [API du classifieur](#)
 - [Types de données](#)
 - [Structure du classifieur](#)
 - [GrokClassifier structure](#)
 - [XMLClassifier structure](#)
 - [JsonClassifier structure](#)
 - [CsvClassifier structure](#)
 - [CreateGrokClassifierRequest structure](#)
 - [UpdateGrokClassifierRequest structure](#)
 - [Créer une structure XMLClassifier de demande](#)
 - [Structure de XMLClassifier demande de mise à jour](#)
 - [CreateJsonClassifierRequest structure](#)
 - [UpdateJsonClassifierRequest structure](#)
 - [CreateCsvClassifierRequest structure](#)
 - [UpdateCsvClassifierRequest structure](#)
 - [Opérations](#)
 - [CreateClassifier action \(Python : create_classifier\)](#)
 - [DeleteClassifier action \(Python : delete_classifier\)](#)
 - [GetClassifier action \(Python : get_classifier\)](#)
 - [GetClassifiers action \(Python : get_classifiers\)](#)
 - [UpdateClassifier action \(Python : update_classifier\)](#)
 - [API du crawler](#)
 - [Types de données](#)
 - [Structure du crawler](#)

- [Structure du planificateur](#)
- [CrawlerTargets structure](#)
- [Structure de la S3Target](#)
- [DeltaCatalogTarget Structure S3](#)
- [DeltaDirectTarget Structure S3](#)
- [JdbcTarget structure](#)
- [Structure Mongo DBTarget](#)
- [Structure de la dynamo DBTarget](#)
- [DeltaTarget structure](#)
- [IcebergTarget structure](#)
- [HudiTarget structure](#)
- [CatalogTarget structure](#)
- [CrawlerMetrics structure](#)
- [CrawlerHistory structure](#)
- [CrawlsFilter structure](#)
- [SchemaChangePolicy structure](#)
- [LastCrawlInfo structure](#)
- [RecrawlPolicy structure](#)
- [LineageConfiguration structure](#)
- [LakeFormationConfiguration structure](#)
- [Opérations](#)
- [CreateCrawler action \(Python : create_crawler\)](#)
- [DeleteCrawler action \(Python : delete_crawler\)](#)
- [GetCrawler action \(Python : get_crawler\)](#)
- [GetCrawlers action \(Python : get_crawlers\)](#)
- [GetCrawlerMetrics action \(Python : get_crawler_metrics\)](#)
- [UpdateCrawler action \(Python : update_crawler\)](#)
- [StartCrawler action \(Python : start_crawler\)](#)
- [StopCrawler action \(Python : stop_crawler\)](#)
- [BatchGetCrawlers action \(Python : batch_get_crawlers\)](#)

- [ListCrawlers action \(Python : list_crawlers\)](#)
- [ListCrawls action \(Python : list_crawls\)](#)
- [API de statistiques de colonne](#)
 - [Types de données](#)
 - [ColumnStatisticsTaskRun structure](#)
 - [ColumnStatisticsTaskSettings structure](#)
 - [ExecutionAttempt structure](#)
 - [Opérations](#)
 - [StartColumnStatisticsTaskRun action \(Python : start_column_statistics_task_run\)](#)
 - [GetColumnStatisticsTaskRun action \(Python : get_column_statistics_task_run\)](#)
 - [GetColumnStatisticsTaskRuns action \(Python : get_column_statistics_task_runs\)](#)
 - [ListColumnStatisticsTaskRuns action \(Python : list_column_statistics_task_runs\)](#)
 - [StopColumnStatisticsTaskRun action \(Python : stop_column_statistics_task_run\)](#)
 - [CreateColumnStatisticsTaskSettings action \(Python : create_column_statistics_task_settings\)](#)
 - [UpdateColumnStatisticsTaskSettings action \(Python : update_column_statistics_task_settings\)](#)
 - [GetColumnStatisticsTaskSettings action \(Python : get_column_statistics_task_settings\)](#)
 - [DeleteColumnStatisticsTaskSettings action \(Python : delete_column_statistics_task_settings\)](#)
 - [StartColumnStatisticsTaskRunSchedule action \(Python : start_column_statistics_task_run_schedule\)](#)
 - [StopColumnStatisticsTaskRunSchedule action \(Python : stop_column_statistics_task_run_schedule\)](#)
 - [Exceptions](#)
 - [ColumnStatisticsTaskRunningException structure](#)
 - [ColumnStatisticsTaskNotRunningException structure](#)
 - [ColumnStatisticsTaskStoppingException structure](#)
 - [ColumnStatisticsTaskAutoConcurrencyLimitException structure](#)
 - [InvalidCatalogSettingException structure](#)
- [API du planificateur du crawler](#)
 - [Types de données](#)

- [Structure du planificateur](#)
- [Opérations](#)
- [UpdateCrawlerSchedule action \(Python : update_crawler_schedule\)](#)
- [StartCrawlerSchedule action \(Python : start_crawler_schedule\)](#)
- [StopCrawlerSchedule action \(Python : stop_crawler_schedule\)](#)
- [Génération automatique d'API de scripts ETL](#)
 - [Types de données](#)
 - [CodeGenNode structure](#)
 - [CodeGenNodeArg structure](#)
 - [CodeGenEdge structure](#)
 - [Structure de l'emplacement](#)
 - [CatalogEntry structure](#)
 - [MappingEntry structure](#)
 - [Opérations](#)
 - [CreateScript action \(Python : créer_script\)](#)
 - [GetDataflowGraph action \(Python : get_dataflow_graph\)](#)
 - [GetMapping action \(Python : get_mapping\)](#)
 - [GetPlan action \(Python : get_plan\)](#)
- [API Visual Job](#)
 - [Types de données](#)
 - [CodeGenConfigurationNode structure](#)
 - [JDBCConnectorStructure des options](#)
 - [StreamingDataPreviewOptions structure](#)
 - [AthenaConnectorSource structure](#)
 - [JDBCConnectorStructure de la source](#)
 - [SparkConnectorSource structure](#)
 - [CatalogSource structure](#)
 - [Structure SQLCatalog de ma source](#)
 - [Structure de la SQL Catalog source Postgre](#)
 - [Structure d'Oracle SQLCatalog Source](#)

- [SQLServerCatalogSource Structure de Microsoft](#)
- [CatalogKinesisSource structure](#)
- [DirectKinesisSource structure](#)
- [KinesisStreamingSourceOptions structure](#)
- [CatalogKafkaSource structure](#)
- [DirectKafkaSource structure](#)
- [KafkaStreamingSourceOptions structure](#)
- [RedshiftSource structure](#)
- [AmazonRedshiftSource structure](#)
- [AmazonRedshiftNodeData structure](#)
- [AmazonRedshiftAdvancedOption structure](#)
- [Structure de l'option](#)
- [CatalogSource Structure S3](#)
- [SourceAdditionalOptions Structure S3](#)
- [CsvSource Structure S3](#)
- [JDBCSource Structure directe](#)
- [DirectSourceAdditionalOptions Structure S3](#)
- [JsonSource Structure S3](#)
- [ParquetSource Structure S3](#)
- [DeltaSource Structure S3](#)
- [CatalogDeltaSource Structure S3](#)
- [CatalogDeltaSource structure](#)
- [HudiSource Structure S3](#)
- [CatalogHudiSource Structure S3](#)
- [ExcelSource Structure S3](#)
- [CatalogHudiSource structure](#)
- [Structure de Dynamo DBCatalog Source](#)
- [RelationalCatalogSource structure](#)
- [JDBCConnectorStructure de la cible](#)
- [SparkConnectorTarget structure](#)

- [BasicCatalogTarget structure](#)
- [Structure de My SQLCatalog Target](#)
- [Structure de SQLCatalog PostgreTarget](#)
- [Structure d'Oracle SQLCatalog Target](#)
- [SQLServerCatalogTarget Structure de Microsoft](#)
- [RedshiftTarget structure](#)
- [AmazonRedshiftTarget structure](#)
- [UpsertRedshiftTargetOptions structure](#)
- [CatalogTarget Structure S3](#)
- [GlueParquetTarget Structure S3](#)
- [CatalogSchemaChangePolicy structure](#)
- [DirectTarget Structure S3](#)
- [HudiCatalogTarget Structure S3](#)
- [HudiDirectTarget Structure S3](#)
- [DeltaCatalogTarget Structure S3](#)
- [DeltaDirectTarget Structure S3](#)
- [HyperDirectTarget Structure S3](#)
- [IcebergDirectTarget Structure S3](#)
- [DirectSchemaChangePolicy structure](#)
- [ApplyMapping structure](#)
- [Structure de mappage](#)
- [SelectFields structure](#)
- [DropFields structure](#)
- [RenameField structure](#)
- [Structure Spigot](#)
- [Structure Join](#)
- [JoinColumn structure](#)
- [SplitFields structure](#)
- [SelectFromCollection structure](#)
- [FillMissingValues structure](#)

- [Structure Filtre](#)
- [FilterExpression structure](#)
- [FilterValue structure](#)
- [CustomCode structure](#)
- [Structure SparkSQL](#)
- [SqlAlias structure](#)
- [DropNullFields structure](#)
- [NullCheckBoxList structure](#)
- [NullValueField structure](#)
- [Structure Datatype](#)
- [Structure Fusion](#)
- [Structure Union](#)
- [PIIDetection structure](#)
- [Structure Aggregate](#)
- [DropDuplicates structure](#)
- [GovernedCatalogTarget structure](#)
- [GovernedCatalogSource structure](#)
- [AggregateOperation structure](#)
- [GlueSchema structure](#)
- [GlueStudioSchemaColumn structure](#)
- [GlueStudioColumn structure](#)
- [DynamicTransform structure](#)
- [TransformConfigParameter structure](#)
- [EvaluateDataQuality structure](#)
- [DQResultsPublishingOptions structure](#)
- [DQStopJobOnFailureOptions structure](#)
- [EvaluateDataQualityMultiFrame structure](#)
- [Structure de la recette](#)
- [RecipeReference structure](#)
- [SnowflakeNodeData structure](#)

- [SnowflakeSource structure](#)
- [SnowflakeTarget structure](#)
- [ConnectorDataSource structure](#)
- [ConnectorDataTarget structure](#)
- [RecipeStep structure](#)
- [RecipeAction structure](#)
- [ConditionExpression structure](#)
- [API de tâches](#)
 - [Tâches](#)
 - [Types de données](#)
 - [Structure Job](#)
 - [ExecutionProperty structure](#)
 - [NotificationProperty structure](#)
 - [JobCommand structure](#)
 - [ConnectionsList structure](#)
 - [JobUpdate structure](#)
 - [SourceControlDetails structure](#)
 - [Opérations](#)
 - [CreateJob action \(Python : create_job\)](#)
 - [UpdateJob action \(Python : update_job\)](#)
 - [GetJob action \(Python : get_job\)](#)
 - [GetJobs action \(Python : get_jobs\)](#)
 - [DeleteJob action \(Python : supprimer_tâche\)](#)
 - [ListJobs action \(Python : list_jobs\)](#)
 - [BatchGetJobs action \(Python : batch_get_jobs\)](#)
 - [Exécutions de tâches](#)
 - [Types de données](#)
 - [JobRun structure](#)
 - [Structure de Predecessor](#)
 - [JobBookmarkEntry structure](#)

- [BatchStopJobRunSuccessfulSubmission structure](#)
- [BatchStopJobRunError structure](#)
- [NotificationProperty structure](#)
- [Opérations](#)
- [StartJobRun action \(Python : start_job_run\)](#)
- [BatchStopJobRun action \(Python : batch_stop_job_run\)](#)
- [GetJobRun action \(Python : get_job_run\)](#)
- [GetJobRuns action \(Python : get_job_runs\)](#)
- [GetJobBookmark action \(Python : get_job_bookmark\)](#)
- [GetJobBookmarks action \(Python : get_job_bookmarks\)](#)
- [ResetJobBookmark action \(Python : reset_job_bookmark\)](#)
- [Déclencheurs](#)
 - [Types de données](#)
 - [Structure Trigger](#)
 - [TriggerUpdate structure](#)
 - [Structure Predicate](#)
 - [Structure Condition](#)
 - [Structure Action](#)
 - [EventBatchingCondition structure](#)
 - [Opérations](#)
 - [CreateTrigger action \(Python : create_trigger\)](#)
 - [StartTrigger action \(Python : start_trigger\)](#)
 - [GetTrigger action \(Python : get_trigger\)](#)
 - [GetTriggers action \(Python : get_triggers\)](#)
 - [UpdateTrigger action \(Python : update_trigger\)](#)
 - [StopTrigger action \(Python : stop_trigger\)](#)
 - [DeleteTrigger action \(Python : delete_trigger\)](#)
 - [ListTriggers action \(Python : list_triggers\)](#)
 - [BatchGetTriggers action \(Python : batch_get_triggers\)](#)
- [Intégration APIs dans AWS Glue](#)

- [Types de données](#)
- [Structure d'intégration](#)
- [IntegrationConfig structure](#)
- [IntegrationPartition structure](#)
- [IntegrationError structure](#)
- [IntegrationFilter structure](#)
- [InboundIntegration structure](#)
- [SourceProcessingProperties structure](#)
- [TargetProcessingProperties structure](#)
- [SourceTableConfig structure](#)
- [TargetTableConfig structure](#)
- [Opérations](#)
- [CreateIntegration action \(Python : create_integration\)](#)
- [ModifyIntegration action \(Python : modifier_intégration\)](#)
- [DescribeIntegrations action \(Python : describe_integrations\)](#)
- [DeleteIntegration action \(Python : delete_integration\)](#)
- [DescribeInboundIntegrations action \(Python : describe_inbound_integrations\)](#)
- [CreateIntegrationTableProperties action \(Python : create_integration_table_properties\)](#)
- [UpdateIntegrationTableProperties action \(Python : update_integration_table_properties\)](#)
- [GetIntegrationTableProperties action \(Python : get_integration_table_properties\)](#)
- [DeleteIntegrationTableProperties action \(Python : delete_integration_table_properties\)](#)
- [CreateIntegrationResourceProperty action \(Python : create_integration_resource_property\)](#)
- [UpdateIntegrationResourceProperty action \(Python : update_integration_resource_property\)](#)
- [GetIntegrationResourceProperty action \(Python : get_integration_resource_property\)](#)
- [UntagResource action \(Python : untag_resource\)](#)
- [ListTagsForResource action \(Python : list_tags_for_resource\)](#)
- [Exceptions](#)
- [ResourceNotFoundException structure](#)
- [InternalServerException structure](#)
- [IntegrationAlreadyExistsFault structure](#)

- [IntegrationConflictOperationFault structure](#)
- [IntegrationQuotaExceededFault structure](#)
- [KMSKeyNotAccessibleFault structure](#)
- [IntegrationNotFoundFault structure](#)
- [TargetResourceNotFound structure](#)
- [InvalidIntegrationStateFault structure](#)
- [Séances interactives API](#)
 - [Types de données](#)
 - [Structure de séance](#)
 - [SessionCommand structure](#)
 - [Structure de la déclaration](#)
 - [StatementOutput structure](#)
 - [StatementOutputData structure](#)
 - [ConnectionsList structure](#)
 - [Opérations](#)
 - [CreateSession action \(Python : créer_session\)](#)
 - [StopSession action \(Python : stop_session\)](#)
 - [DeleteSession action \(Python : supprimer_session\)](#)
 - [GetSession action \(Python : get_session\)](#)
 - [ListSessions action \(Python : list_sessions\)](#)
 - [RunStatement action \(Python : run_statement\)](#)
 - [CancelStatement action \(Python : annuler_statement\)](#)
 - [GetStatement action \(Python : get_statement\)](#)
 - [ListStatements action \(Python : list_statements\)](#)
- [API de points de terminaison de développement](#)
 - [Types de données](#)
 - [DevEndpoint structure](#)
 - [DevEndpointCustomLibraries structure](#)
 - [Opérations](#)
 - [CreateDevEndpoint action \(Python : create_dev_endpoint\)](#)

- [UpdateDevEndpoint action \(Python : update_dev_endpoint\)](#)
- [DeleteDevEndpoint action \(Python : delete_dev_endpoint\)](#)
- [GetDevEndpoint action \(Python : get_dev_endpoint\)](#)
- [GetDevEndpoints action \(Python : get_dev_endpoints\)](#)
- [BatchGetDevEndpoints action \(Python : batch_get_dev_endpoints\)](#)
- [ListDevEndpoints action \(Python : list_dev_endpoints\)](#)
- [Registre de schémas](#)
 - [Types de données](#)
 - [RegistryId structure](#)
 - [RegistryListItem structure](#)
 - [MetadataInfo structure](#)
 - [OtherMetadataValueListItem structure](#)
 - [SchemaListItem structure](#)
 - [SchemaVersionListItem structure](#)
 - [MetadataKeyValuePair structure](#)
 - [SchemaVersionErrorItem structure](#)
 - [ErrorDetails structure](#)
 - [SchemaVersionNumber structure](#)
 - [Schemald structure](#)
 - [Opérations](#)
 - [CreateRegistry action \(Python : create_registry\)](#)
 - [CreateSchema action \(Python : créer schéma\)](#)
 - [GetSchema action \(Python : get_schema\)](#)
 - [ListSchemaVersions action \(Python : list_schema_versions\)](#)
 - [GetSchemaVersion action \(Python : get_schema_version\)](#)
 - [GetSchemaVersionsDiff action \(Python : get_schema_versions_diff\)](#)
 - [ListRegistries action \(Python : list_registries\)](#)
 - [ListSchemas action \(Python : list_schemas\)](#)
 - [RegisterSchemaVersion action \(Python : register_schema_version\)](#)
 - [UpdateSchema action \(Python : update_schema\)](#)

- [CheckSchemaVersionValidity action \(Python : check_schema_version_validity\)](#)
- [UpdateRegistry action \(Python : update_registry\)](#)
- [GetSchemaByDefinition action \(Python : get_schema_by_definition\)](#)
- [GetRegistry action \(Python : get_registry\)](#)
- [PutSchemaVersionMetadata action \(Python : put_schema_version_metadata\)](#)
- [QuerySchemaVersionMetadata action \(Python : query_schema_version_metadata\)](#)
- [RemoveSchemaVersionMetadata action \(Python : remove_schema_version_metadata\)](#)
- [DeleteRegistry action \(Python : supprimer_registre\)](#)
- [DeleteSchema action \(Python : supprimer_schéma\)](#)
- [DeleteSchemaVersions action \(Python : delete_schema_versions\)](#)
- [Flux de travail](#)
 - [Types de données](#)
 - [JobNodeDetails structure](#)
 - [CrawlerNodeDetails structure](#)
 - [TriggerNodeDetails structure](#)
 - [Structure Crawl](#)
 - [Structure de nœud](#)
 - [Structure Edge](#)
 - [Structure de flux de travail](#)
 - [WorkflowGraph structure](#)
 - [WorkflowRun structure](#)
 - [WorkflowRunStatistics structure](#)
 - [StartingEventBatchCondition structure](#)
 - [Structure du plan](#)
 - [BlueprintDetails structure](#)
 - [LastActiveDefinition structure](#)
 - [BlueprintRun structure](#)
 - [Opérations](#)
 - [CreateWorkflow action \(Python : create_workflow\)](#)
 - [UpdateWorkflow action \(Python : update_workflow\)](#)

- [DeleteWorkflow action \(Python : delete_workflow\)](#)
- [GetWorkflow action \(Python : get_workflow\)](#)
- [ListWorkflows action \(Python : list_workflows\)](#)
- [BatchGetWorkflows action \(Python : batch_get_workflows\)](#)
- [GetWorkflowRun action \(Python : get_workflow_run\)](#)
- [GetWorkflowRuns action \(Python : get_workflow_runs\)](#)
- [GetWorkflowRunProperties action \(Python : get_workflow_run_properties\)](#)
- [PutWorkflowRunProperties action \(Python : put_workflow_run_properties\)](#)
- [CreateBlueprint action \(Python : créer_blueprint\)](#)
- [UpdateBlueprint action \(Python : update_blueprint\)](#)
- [DeleteBlueprint action \(Python : delete_blueprint\)](#)
- [ListBlueprints action \(Python : list_blueprints\)](#)
- [BatchGetBlueprints action \(Python : batch_get_blueprints\)](#)
- [StartBlueprintRun action \(Python : start_blueprint_run\)](#)
- [GetBlueprintRun action \(Python : get_blueprint_run\)](#)
- [GetBlueprintRuns action \(Python : get_blueprint_runs\)](#)
- [StartWorkflowRun action \(Python : start_workflow_run\)](#)
- [StopWorkflowRun action \(Python : stop_workflow_run\)](#)
- [ResumeWorkflowRun action \(Python : resume_workflow_run\)](#)
- [Profils d'utilisation](#)
 - [Types de données](#)
 - [ProfileConfiguration structure](#)
 - [ConfigurationObject structure](#)
 - [UsageProfileDefinition structure](#)
 - [Opérations](#)
 - [CreateUsageProfile action \(Python : create_usage_profile\)](#)
 - [GetUsageProfile action \(Python : get_usage_profile\)](#)
 - [UpdateUsageProfile action \(Python : update_usage_profile\)](#)
 - [DeleteUsageProfile action \(Python : delete_usage_profile\)](#)
 - [ListUsageProfiles action \(Python : list_usage_profiles\)](#)

- [API de Machine Learning](#)
 - [Types de données](#)
 - [TransformParameters structure](#)
 - [EvaluationMetrics structure](#)
 - [MLTransform structure](#)
 - [FindMatchesParameters structure](#)
 - [FindMatchesMetrics structure](#)
 - [ConfusionMatrix structure](#)
 - [GlueTable structure](#)
 - [TaskRun structure](#)
 - [TransformFilterCriteria structure](#)
 - [TransformSortCriteria structure](#)
 - [TaskRunFilterCriteria structure](#)
 - [TaskRunSortCriteria structure](#)
 - [TaskRunProperties structure](#)
 - [FindMatchesTaskRunProperties structure](#)
 - [ImportLabelsTaskRunProperties structure](#)
 - [ExportLabelsTaskRunProperties structure](#)
 - [LabelingSetGenerationTaskRunProperties structure](#)
 - [SchemaColumn structure](#)
 - [TransformEncryption structure](#)
 - [MLUserDataEncryption structure](#)
 - [ColumnImportance structure](#)
 - [Opérations](#)
 - [Créer une MLTransform action \(Python : create_ml_transform\)](#)
 - [MLTransform Action de mise à jour \(Python : update_ml_transform\)](#)
 - [MLTransform Action de suppression \(Python : delete_ml_transform\)](#)
 - [Obtenir une MLTransform action \(Python : get_ml_transform\)](#)
 - [Obtenir une ML Transforms action \(Python : get_ml_transform\)](#)
- [MLTransforms Action de liste \(Python : list_ml_transform\)](#)

- [Lancer MLEvaluation TaskRun l'action \(Python : start_ml_evaluation_task_run\)](#)
- [Lancer MLLabeling SetGenerationTaskRun l'action \(Python : start_ml_labeling_set_generation_task_run\)](#)
- [Action Get MLTask Run \(Python : get_ml_task_run\)](#)
- [Action Get MLTask Runs \(Python : get_ml_task_runs\)](#)
- [Annuler l'action MLTask Exécuter \(Python : cancel_ml_task_run\)](#)
- [StartExportLabelsTaskRun action \(Python : start_export_labels_task_run\)](#)
- [StartImportLabelsTaskRun action \(Python : start_import_labels_task_run\)](#)
- [API Qualité des données](#)
 - [Types de données](#)
 - [DataSource structure](#)
 - [DataQualityRulesetListDetails structure](#)
 - [DataQualityTargetTable structure](#)
 - [DataQualityRulesetEvaluationRunDescription structure](#)
 - [DataQualityRulesetEvaluationRunFilter structure](#)
 - [DataQualityEvaluationRunAdditionalRunOptions structure](#)
 - [DataQualityRuleRecommendationRunDescription structure](#)
 - [DataQualityRuleRecommendationRunFilter structure](#)
 - [DataQualityResult structure](#)
 - [DataQualityAnalyzerResult structure](#)
 - [DataQualityObservation structure](#)
 - [MetricBasedObservation structure](#)
 - [DataQualityMetricValues structure](#)
 - [DataQualityRuleResult structure](#)
 - [DataQualityResultDescription structure](#)
 - [DataQualityResultFilterCriteria structure](#)
 - [DataQualityRulesetFilterCriteria structure](#)
 - [DataQualityAggregatedMetrics structure](#)
 - [StatisticAnnotation structure](#)
 - [TimestampedInclusionAnnotation structure](#)

- [AnnotationError structure](#)
- [DatapointInclusionAnnotation structure](#)
- [StatisticSummaryList liste](#)
- [StatisticSummary structure](#)
- [RunIdentifier structure](#)
- [StatisticModelResult structure](#)
- [Opérations](#)
- [StartDataQualityRulesetEvaluationRun action \(Python : `start\_data\_quality\_ruleset\_evaluation\_run`\)](#)
- [CancelDataQualityRulesetEvaluationRun action \(Python : `cancel\_data\_quality\_ruleset\_evaluation\_run`\)](#)
- [GetDataQualityRulesetEvaluationRun action \(Python : `get\_data\_quality\_ruleset\_evaluation\_run`\)](#)
- [ListDataQualityRulesetEvaluationRuns action \(Python : `list\_data\_quality\_ruleset\_evaluation\_runs`\)](#)
- [StartDataQualityRuleRecommendationRun action \(Python : `start\_data\_quality\_rule\_recommendation\_run`\)](#)
- [CancelDataQualityRuleRecommendationRun action \(Python : `cancel\_data\_quality\_rule\_recommendation\_run`\)](#)
- [GetDataQualityRuleRecommendationRun action \(Python : `get\_data\_quality\_rule\_recommendation\_run`\)](#)
- [ListDataQualityRuleRecommendationRuns action \(Python : `list\_data\_quality\_rule\_recommendation\_runs`\)](#)
- [GetDataQualityResult action \(Python : `get\_data\_quality\_result`\)](#)
- [BatchGetDataQualityResult action \(Python : `batch\_get\_data\_quality\_result`\)](#)
- [ListDataQualityResults action \(Python : `list\_data\_quality\_results`\)](#)
- [CreateDataQualityRuleset action \(Python : `create\_data\_quality\_ruleset`\)](#)
- [DeleteDataQualityRuleset action \(Python : `delete\_data\_quality\_ruleset`\)](#)
- [GetDataQualityRuleset action \(Python : `get\_data\_quality\_ruleset`\)](#)
- [ListDataQualityRulesets action \(Python : `list\_data\_quality\_rulesets`\)](#)
- [UpdateDataQualityRuleset action \(Python : `update\_data\_quality\_ruleset`\)](#)
- [ListDataQualityStatistics action \(Python : `list\_data\_quality\_statistics`\)](#)

- [TimestampFilter structure](#)
- [CreateDataQualityRulesetRequest structure](#)
- [GetDataQualityRulesetResponse structure](#)
- [GetDataQualityResultResponse structure](#)
- [StartDataQualityRuleRecommendationRunRequest structure](#)
- [GetDataQualityRuleRecommendationRunResponse structure](#)
- [BatchPutDataQualityStatisticAnnotation action \(Python : `batch\_put\_data\_quality\_statistic\_annotation`\)](#)
- [GetDataQualityModel action \(Python : `get\_data\_quality\_model`\)](#)
- [GetDataQualityModelResult action \(Python : `get\_data\_quality\_model\_result`\)](#)
- [ListDataQualityStatisticAnnotations action \(Python : `list\_data\_quality\_statistic\_annotations`\)](#)
- [PutDataQualityProfileAnnotation action \(Python : `put\_data\_quality\_profile\_annotation`\)](#)
- [API Détection des données sensibles](#)
 - [Types de données](#)
 - [CustomEntityType structure](#)
 - [Opérations](#)
 - [CreateCustomEntityType action \(Python : `create\_custom\_entity\_type`\)](#)
 - [DeleteCustomEntityType action \(Python : `delete\_custom\_entity\_type`\)](#)
 - [GetCustomEntityType action \(Python : `get\_custom\_entity\_type`\)](#)
 - [BatchGetCustomEntityTypes action \(Python : `batch\_get\_custom\_entity\_types`\)](#)
 - [ListCustomEntityTypes action \(Python : `list\_custom\_entity\_types`\)](#)
- [Marquage APIs AWS Glue](#)
 - [Types de données](#)
 - [Structure Tag](#)
 - [Opérations](#)
 - [TagResource action \(Python : `tag\_resource`\)](#)
 - [UntagResource action \(Python : `untag\_resource`\)](#)
 - [GetTags action \(Python : `get\_tags`\)](#)
- [Types de données courants](#)
 - [Structure de balise](#)

- [DecimalNumber structure](#)
- [ErrorDetail structure](#)
- [PropertyPredicate structure](#)
- [ResourceUri structure](#)
- [ColumnStatistics structure](#)
- [ColumnStatisticsError structure](#)
- [ColumnError structure](#)
- [ColumnStatisticsData structure](#)
- [BooleanColumnStatisticsData structure](#)
- [DateColumnStatisticsData structure](#)
- [DecimalColumnStatisticsData structure](#)
- [DoubleColumnStatisticsData structure](#)
- [LongColumnStatisticsData structure](#)
- [StringColumnStatisticsData structure](#)
- [BinaryColumnStatisticsData structure](#)
- [Modèles de chaîne](#)
- [Exceptions](#)
 - [AccessDeniedException structure](#)
 - [AlreadyExistsException structure](#)
 - [ConcurrentModificationException structure](#)
 - [ConcurrentRunsExceededException structure](#)
 - [CrawlerNotRunningException structure](#)
 - [CrawlerRunningException structure](#)
 - [CrawlerStoppingException structure](#)
 - [EntityNotFoundException structure](#)
 - [FederationSourceException structure](#)
 - [FederationSourceRetryableException structure](#)
 - [GlueEncryptionException structure](#)
 - [IdempotentParameterMismatchException structure](#)
 - [IllegalWorkflowStateException structure](#)

- [InternalServiceException structure](#)
- [InvalidExecutionEngineException structure](#)
- [InvalidInputException structure](#)
- [InvalidStateException structure](#)
- [InvalidTaskStatusTransitionException structure](#)
- [JobDefinitionErrorException structure](#)
- [JobRunInTerminalStateException structure](#)
- [JobRunInvalidStateTransitionException structure](#)
- [JobRunNotInTerminalStateException structure](#)
- [LateRunnerException structure](#)
- [NoScheduleException structure](#)
- [OperationTimeoutException structure](#)
- [ResourceNotReadyException structure](#)
- [ResourceNumberLimitExceededException structure](#)
- [SchedulerNotRunningException structure](#)
- [SchedulerRunningException structure](#)
- [SchedulerTransitioningException structure](#)
- [UnrecognizedRunnerException structure](#)
- [ValidationException structure](#)
- [VersionMismatchException structure](#)

Sécurité APIs dans AWS Glue

L'API de sécurité décrit les types de données de sécurité et l'API associée à la sécurité dans AWS Glue.

Types de données

- [DataCatalogEncryptionSettings structure](#)
- [EncryptionAtRest structure](#)
- [ConnectionPasswordEncryption structure](#)
- [EncryptionConfiguration structure](#)

- [Structure S3Encryption](#)
- [CloudWatchEncryption structure](#)
- [JobBookmarksEncryption structure](#)
- [SecurityConfiguration structure](#)
- [GluePolicy structure](#)
- [DataQualityEncryption structure](#)

DataCatalogEncryptionSettings structure

Contient des informations de configuration sur le maintien de la sécurité du catalogue de données.

Champs

- `EncryptionAtRest` – Un objet [EncryptionAtRest](#).

Spécifie la encryption-at-rest configuration du catalogue de données.

- `ConnectionPasswordEncryption` – Un objet [ConnectionPasswordEncryption](#).

Lorsque la protection par mot de passe de connexion est activée, le Catalogue de données utilise une clé fournie par le client pour chiffrer le mot de passe dans le cadre de `CreateConnection` ou `UpdateConnection` et le stocke dans le champ `ENCRYPTED_PASSWORD` des propriétés de connexion. Vous pouvez activer le chiffage de catalogue ou uniquement le chiffage de mot de passe.

EncryptionAtRest structure

Spécifie la encryption-at-rest configuration du catalogue de données.

Champs

- `CatalogEncryptionMode` – Obligatoire : Chaîne UTF-8 (valeurs valides : `DISABLED` | `SSE-KMS="SSEKMS"` | `SSE-KMS-WITH-SERVICE-ROLE="SSEKMSWITHSERVICEROLE"`).

encryption-at-restMode de chiffrement des données du catalogue de données.

- `SseAwsKmsKeyId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de la AWS KMS clé à utiliser pour le chiffrement au repos.

- `CatalogEncryptionServiceRole` – Chaîne UTF-8, correspondant au [Custom string pattern #51](#).

Rôle censé chiffrer et déchiffrer les objets du catalogue de données pour le compte de l'appelant.
AWS Glue

ConnectionPasswordEncryption structure

La structure des données utilisée par le Catalogue de données pour chiffrer le mot de passe dans le cadre de `CreateConnection` ou `UpdateConnection` et le stocker dans le champ `ENCRYPTED_PASSWORD` des propriétés de connexion. Vous pouvez activer le chiffage de catalogue ou uniquement le chiffage de mot de passe.

Lorsqu'une `CreationConnection` demande contenant un mot de passe arrive, le catalogue de données chiffre d'abord le mot de passe à l'aide de votre AWS KMS clé. Il chiffre de nouveau l'objet de connexion entier si le chiffage de catalogue est également activé.

Ce chiffrement nécessite que vous définissiez des autorisations AWS KMS clés pour activer ou restreindre l'accès à la clé de mot de passe conformément à vos exigences de sécurité. Par exemple, vous pourriez vouloir autoriser uniquement des administrateurs à disposer des autorisations de déchiffrement de la clé de mot de passe.

Champs

- `ReturnConnectionPasswordEncrypted` – obligatoire : booléen.

Lorsque le signalment `ReturnConnectionPasswordEncrypted` est réglé sur « vrai », les mots de passe restent chiffrés dans les réponses de `GetConnection` et de `GetConnections`. Ce chiffage prend effet indépendamment du chiffage de catalogue.

- `AwsKmsKeyId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

AWS KMS Clé utilisée pour chiffrer le mot de passe de connexion.

Si la protection par mot de passe de connexion est activée, l'`CreateConnection` appelant `UpdateConnection` doit au moins `kms:Encrypt` obtenir une autorisation sur la AWS KMS clé spécifiée pour chiffrer les mots de passe avant de les stocker dans le catalogue de données.

Vous pouvez régler l'autorisation de déchiffrement pour activer ou restreindre l'accès à la clé de mot de passe selon vos exigences de sécurité.

EncryptionConfiguration structure

Spécifie une configuration de chiffrement.

Champs

- `S3Encryption` – Un tableau d'objets [S3Encryption](#).

Configuration de chiffrement pour les données Amazon Simple Storage Service (Amazon S3).

- `CloudWatchEncryption` – Un objet [CloudWatchEncryption](#).

Configuration du chiffrement pour Amazon CloudWatch.

- `JobBookmarksEncryption` – Un objet [JobBookmarksEncryption](#).

Configuration de chiffrement pour les signets de tâche.

- `DataQualityEncryption` – Un objet [DataQualityEncryption](#).

Configuration du chiffrement pour les actifs de qualité des AWS Glue données.

Structure S3Encryption

Spécifie la façon dont les données Amazon Simple Storage Service (Amazon S3) doivent être chiffrées.

Champs

- `S3EncryptionMode` – Chaîne UTF-8 (valeurs valides : `DISABLED` | `SSE-KMS="SSEKMS"` | `SSE-S3="SSES3"`).

Mode de chiffrement à utiliser pour les données Amazon S3.

- `KmsKeyArn` – Chaîne UTF-8, correspondant au [Custom string pattern #29](#).

L'Amazon Resource Name (ARN) de la clé KMS à utiliser pour chiffrer les données.

CloudWatchEncryption structure

Spécifie la manière dont CloudWatch les données Amazon doivent être cryptées.

Champs

- `CloudWatchEncryptionMode` – Chaîne UTF-8 (valeurs valides : `DISABLED` | `SSE-KMS="SSEKMS"`).

Mode de chiffrement à utiliser pour les CloudWatch données.

- `KmsKeyArn` – Chaîne UTF-8, correspondant au [Custom string pattern #29](#).

L'Amazon Resource Name (ARN) de la clé KMS à utiliser pour chiffrer les données.

JobBookmarksEncryption structure

Spécifie la manière dont les données de signet de tâche doivent être chiffrées.

Champs

- `JobBookmarksEncryptionMode` – Chaîne UTF-8 (valeurs valides : `DISABLED` | `CSE-KMS="CSEKMS"`).

Mode de chiffrement à utiliser pour les données de signet de tâche.

- `KmsKeyArn` – Chaîne UTF-8, correspondant au [Custom string pattern #29](#).

L'Amazon Resource Name (ARN) de la clé KMS à utiliser pour chiffrer les données.

SecurityConfiguration structure

Spécifie une configuration de sécurité.

Champs

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité.

- `CreatedTimeStamp` – Horodatage.

Horodatage de la création de la configuration de sécurité.

- `EncryptionConfiguration` – Un objet [EncryptionConfiguration](#).

Configuration de chiffrement associée à cette configuration de sécurité.

GluePolicy structure

Structure pour le renvoi d'une politique de ressources.

Champs

- `PolicyInJson` — Chaîne UTF-8, d'une longueur minimale de 2 octets.

Contient le document de politique demandé, au format JSON.

- `PolicyHash` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Contient la valeur de hachage associée à cette politique.

- `CreateTime` – Horodatage.

Date et heure de création de la politique.

- `UpdateTime` – Horodatage.

Date et heure de dernière mise à jour de la politique.

DataQualityEncryption structure

Spécifie la manière dont les actifs de qualité des données de votre compte doivent être chiffrés.

Champs

- `DataQualityEncryptionMode` – Chaîne UTF-8 (valeurs valides : `DISABLED` | `SSE-KMS="SSEKMS"`).

Mode de chiffrement à utiliser pour chiffrer les actifs relatifs à la qualité des données. Ces actifs incluent des ensembles de règles de qualité des données, des résultats, des statistiques, des modèles de détection des anomalies et des observations.

Les valeurs valides concernent le chiffrement SSEKMS à l'aide d'une clé KMS gérée par le client, ou. DISABLED

- KmsKeyArn – Chaîne UTF-8, correspondant au [Custom string pattern #29](#).

L'Amazon Resource Name (ARN) de la clé KMS à utiliser pour chiffrer les données.

Opérations

- [GetDataCatalogEncryptionSettings action](#) (Python : `get_data_catalog_encryption_settings`)
- [PutDataCatalogEncryptionSettings action](#) (Python : `put_data_catalog_encryption_settings`)
- [PutResourcePolicy action](#) (Python : `put_resource_policy`)
- [GetResourcePolicy action](#) (Python : `get_resource_policy`)
- [DeleteResourcePolicy action](#) (Python : `delete_resource_policy`)
- [CreateSecurityConfiguration action](#) (Python : `create_security_configuration`)
- [DeleteSecurityConfiguration action](#) (Python : `delete_security_configuration`)
- [GetSecurityConfiguration action](#) (Python : `get_security_configuration`)
- [GetSecurityConfigurations action](#) (Python : `get_security_configurations`)
- [GetResourcePolicies action](#) (Python : `get_resource_policies`)

GetDataCatalogEncryptionSettings action (Python : `get_data_catalog_encryption_settings`)

Récupère la configuration de sécurité d'un catalogue spécifié.

Demande

- CatalogId – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données pour lequel extraire la configuration de sécurité. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

Réponse

- DataCatalogEncryptionSettings – Un objet [DataCatalogEncryptionSettings](#).

Configuration de sécurité demandée.

Erreurs

- InternalServiceException
- InvalidInputException
- OperationTimeoutException

PutDataCatalogEncryptionSettings action (Python : put_data_catalog_encryption_settings)

Définit la configuration de sécurité d'un catalogue spécifié. Une fois la configuration définie, le chiffrement spécifié est appliqué à chaque écriture ultérieure dans le catalogue.

Demande

- CatalogId – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données pour lequel définir la configuration de sécurité. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- DataCatalogEncryptionSettings – Obligatoire : un objet [DataCatalogEncryptionSettings](#).

Configuration de sécurité à définir.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- InternalServiceException
- InvalidInputException

- `OperationTimeoutException`

PutResourcePolicy action (Python : `put_resource_policy`)

Définit la politique de ressources du catalogue de données pour le contrôle d'accès.

Demande

- `PolicyInJson` – Obligatoire : Chaîne UTF-8, d'une longueur minimale de 2 octets.

Contient le document de politique à définir, au format JSON.

- `ResourceArn` – chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant à [Custom string pattern #49](#).

Ne pas utiliser. Pour utilisation interne uniquement.

- `PolicyHashCondition` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

La valeur de hachage renvoyée lors de la définition de la politique précédente à l'aide de `PutResourcePolicy`. Son objectif est d'empêcher les modifications simultanées d'une politique. N'utilisez pas ce paramètre si aucune politique précédente n'a été définie.

- `PolicyExistsCondition` – Chaîne UTF-8 (valeurs valides : `MUST_EXIST` | `NOT_EXIST` | `NONE`).

La valeur `MUST_EXIST` est utilisée pour mettre à jour une politique. La valeur `NOT_EXIST` est utilisée pour créer une politique. Si une valeur `NONE` ou `null` est utilisée, l'appel ne dépend pas de l'existence d'une politique.

- `EnableHybrid` – Chaîne UTF-8 (valeurs valides : `TRUE` | `FALSE`).

Si la valeur est '`TRUE`', cela indique que vous utilisez les deux méthodes pour accorder un accès entre comptes aux ressources Data Catalog :

- En mettant directement à jour la politique de ressources avec `PutResourcePolicy`
- En utilisant la commande `Grant permissions` (Accorder des autorisations) sur la AWS Management Console.

Doit être défini sur '`TRUE`' si vous avez déjà utilisé la console de gestion pour accorder l'accès entre comptes, sinon l'appel échoue. La valeur par défaut est '`FALSE`'.

Réponse

- PolicyHash – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Un hachage de la politique vient d'être défini. Cela doit être inclus dans un appel ultérieur qui remplace ou met à jour cette politique.

Erreurs

- EntityNotFoundException
- InternalServiceException
- OperationTimeoutException
- InvalidInputException
- ConditionCheckFailureException

GetResourcePolicy action (Python : get_resource_policy)

Extrait une politique de ressource spécifiée.

Demande

- ResourceArn – chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant à [Custom string pattern #49](#).

L'ARN de la AWS Glue ressource pour laquelle vous souhaitez récupérer la politique de ressource. Si elle n'est pas fournie, la politique de ressources Data Catalog est renvoyée. Utilisez GetResourcePolicies pour afficher toutes les politiques de ressources existantes. Pour plus d'informations, voir [Spécification de AWS Glue la ressource ARNs](#).

Réponse

- PolicyInJson — Chaîne UTF-8, d'une longueur minimale de 2 octets.

Contient le document de politique demandé, au format JSON.

- PolicyHash – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Contient la valeur de hachage associée à cette politique.

- `CreateTime` – Horodatage.

Date et heure de création de la politique.

- `UpdateTime` – Horodatage.

Date et heure de dernière mise à jour de la politique.

Erreurs

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

DeleteResourcePolicy action (Python : `delete_resource_policy`)

Supprime une politique spécifiée.

Demande

- `PolicyHashCondition` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Valeur de hachage renvoyée lorsque cette politique a été définie.

- `ResourceArn` – chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant à [Custom string pattern #49](#).

L'ARN de la AWS Glue ressource pour la politique de ressources à supprimer.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ConditionCheckFailureException`

CreateSecurityConfiguration action (Python : `create_security_configuration`)

Crée une nouvelle configuration de sécurité. Une configuration de sécurité est un ensemble de paramètres de sécurité pouvant être utilisées par AWS Glue. Vous pouvez utiliser une configuration de sécurité pour chiffrer les données au repos. Pour plus d'informations sur l'utilisation des configurations de sécurité dans AWS Glue, consultez la section [Chiffrement des données écrites par les robots d'exploration, les tâches et les points de terminaison de développement](#).

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la nouvelle configuration de sécurité.

- **EncryptionConfiguration** – Obligatoire : un objet [EncryptionConfiguration](#).

Configuration de chiffrement associée à la nouvelle configuration de sécurité.

Réponse

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom affecté à la nouvelle configuration de sécurité.

- **CreatedTimestamp** – Horodatage.

Horodatage de la création de la nouvelle configuration de sécurité.

Erreurs

- `AlreadyExistsException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

DeleteSecurityConfiguration action (Python : `delete_security_configuration`)

Supprime une configuration de sécurité spécifiée.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité à supprimer.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

GetSecurityConfiguration action (Python : `get_security_configuration`)

Extrait une configuration de sécurité spécifiée.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité à récupérer.

Réponse

- **SecurityConfiguration** – Un objet [SecurityConfiguration](#).

Configuration de sécurité demandée.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

GetSecurityConfigurations action (Python : `get_security_configurations`)

Extrait une liste de toutes les configurations de sécurité.

Demande

- **MaxResults** – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats à renvoyer.

- **NextToken** – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- **SecurityConfigurations** – Un tableau d'objets [SecurityConfiguration](#).

Liste de configurations de sécurité.

- `NextToken` – Chaîne UTF-8.

Jeton de liaison, s'il y a des configurations de sécurité supplémentaires à renvoyer.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

GetResourcePolicies action (Python : `get_resource_policies`)

Récupère les politiques de ressources définies pour les ressources individuelles AWS Resource Access Manager lors de l'octroi d'autorisations entre comptes. Récupère également la politique de ressources Data Catalog.

Si vous avez activé le chiffrement des métadonnées dans les paramètres du catalogue de données et que vous n'êtes pas autorisé à utiliser la AWS KMS clé, l'opération ne peut pas renvoyer la politique de ressources du catalogue de données.

Demande

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'une requête de continuation.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

La taille maximale d'une liste à renvoyer.

Réponse

- `GetResourcePoliciesResponseList` – Un tableau d'objets [GluePolicy](#).

Liste répertoriant chacune des politiques de ressources et politique de ressources au niveau du compte.

- `NextToken` – Chaîne UTF-8.

Un jeton de continuation, si la liste renvoyée ne contient pas la dernière politique de ressources disponible.

Erreurs

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`

API d'objets de catalogue

L'API des objets du catalogue décrit les types de données et l'API liés à l'utilisation des catalogues dans AWS Glue.

Rubriques

- [API de catalogues](#)
- [API d'une base de données](#)
- [API de table](#)
- [API de partition](#)
- [API de connexions](#)
- [API de fonction définie par l'utilisateur](#)
- [Importation d'un Athena catalogue dans AWS Glue](#)

API de catalogues

L'API Catalogs décrit comment créer, supprimer, localiser, mettre à jour et répertorier les catalogues.
APIs

Types de données

- [Structure du catalogue](#)
- [CatalogInput structure](#)
- [TargetRedshiftCatalog structure](#)

- [CatalogProperties structure](#)
- [CatalogPropertiesOutput structure](#)
- [DataLakeAccessProperties structure](#)
- [DataLakeAccessPropertiesOutput structure](#)
- [FederatedCatalog structure](#)

Structure du catalogue

L'objet de catalogue représente un regroupement logique de bases de données dans le catalogue de AWS Glue données ou dans une source fédérée. Vous pouvez désormais créer un catalogue fédéré Redshift ou un catalogue contenant des liens de ressources vers des bases de données Redshift d'un autre compte ou d'une autre région.

Champs

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue. Pour autoriser l'accès au catalogue par défaut, ce champ ne doit pas être fourni.

- `Name`— Obligatoire : chaîne UTF-8, d'au moins 1 ou plus de 64 octets, correspondant au [Custom string pattern #25](#)

Le nom du catalogue. Il ne peut pas être identique à l'identifiant du compte.

- `ResourceArn` – Chaîne UTF-8.

Le nom de ressource Amazon (ARN) attribué à la ressource du catalogue.

- `Description` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au modèle de chaîne multiligne de l'adresse URI. Description du catalogue.

- `Parameters` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Tableau cartographique de paires clé-valeur qui définissent les paramètres et les propriétés du catalogue.

- `CreateTime` – Horodatage.

Heure à laquelle le catalogue a été créé.

- `UpdateTime` – Horodatage.

Heure à laquelle le catalogue a été mis à jour pour la dernière fois.

- `TargetRedshiftCatalog` – Un objet [TargetRedshiftCatalog](#).

`TargetRedshiftCatalogObjet` qui décrit un catalogue cible pour la liaison de ressources de base de données.

- `FederatedCatalog` – Un objet [FederatedCatalog](#).

`FederatedCatalogObjet` qui pointe vers une entité en dehors du catalogue AWS Glue de données.

- `CatalogProperties` – Un objet [CatalogPropertiesOutput](#).

`CatalogPropertiesObjet` qui spécifie les propriétés d'accès au lac de données et d'autres propriétés personnalisées.

- `CreateTableDefaultPermissions` – Un tableau d'objets [PrincipalPermissions](#).

Tableau d'objets `PrincipalPermissions`. Crée un ensemble d'autorisations par défaut sur les tables pour les principaux. Utilisé par AWS Lake Formation. Non utilisé dans le cours normal des AWS Glue opérations.

- `CreateDatabaseDefaultPermissions` – Un tableau d'objets [PrincipalPermissions](#).

Tableau d'objets `PrincipalPermissions`. Crée un ensemble d'autorisations par défaut sur la ou les bases de données pour les principaux. Utilisé par AWS Lake Formation. Non utilisé dans le cours normal des AWS Glue opérations.

- `AllowFullTableExternalDataAccess` – Chaîne UTF-8 (valeurs valides : `True` | `False`).

Permet à des moteurs tiers d'accéder aux données Amazon S3 situées dans des emplacements enregistrés auprès de Lake Formation.

CatalogInput structure

Structure qui décrit les propriétés du catalogue.

Champs

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au modèle de chaîne multiligne de l'adresse URI. Description du catalogue.

- **FederatedCatalog** – Un objet [FederatedCatalog](#).

Un objet FederatedCatalog. FederatedCatalogStructure qui fait référence à une entité extérieure au catalogue de AWS Glue données, par exemple une base de données Redshift.

- **Parameters** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Tableau cartographique de paires clé-valeur qui définissent les paramètres et les propriétés du catalogue.

- **TargetRedshiftCatalog** – Un objet [TargetRedshiftCatalog](#).

TargetRedshiftCatalogObjet qui décrit un catalogue cible pour la liaison de ressources.

- **CatalogProperties** – Un objet [CatalogProperties](#).

CatalogPropertiesObjet qui spécifie les propriétés d'accès au lac de données et d'autres propriétés personnalisées.

- **CreateTableDefaultPermissions** – Un tableau d'objets [PrincipalPermissions](#).

Tableau d'objets PrincipalPermissions. Crée un ensemble d'autorisations par défaut sur les tables pour les principaux. Utilisé par AWS Lake Formation. Il doit généralement être défini explicitement sous forme de liste vide.

- **CreateDatabaseDefaultPermissions** – Un tableau d'objets [PrincipalPermissions](#).

Tableau d'objets `PrincipalPermissions`. Crée un ensemble d'autorisations par défaut sur la ou les bases de données pour les principaux. Utilisé par AWS Lake Formation. Il doit généralement être défini explicitement sous forme de liste vide.

- `AllowFullTableExternalDataAccess` – Chaîne UTF-8 (valeurs valides : `True` | `False`).

Permet à des moteurs tiers d'accéder aux données Amazon S3 situées dans des emplacements enregistrés auprès de Lake Formation.

TargetRedshiftCatalog structure

Structure qui décrit un catalogue cible pour la liaison de ressources.

Champs

- `CatalogArn` – Obligatoire : chaîne UTF-8.

Le nom de ressource Amazon (ARN) de la ressource du catalogue.

CatalogProperties structure

Structure qui spécifie les propriétés d'accès au lac de données et d'autres propriétés personnalisées.

Champs

- `DataLakeAccessProperties` – Un objet [DataLakeAccessProperties](#).

`DataLakeAccessProperties`Objet qui spécifie les propriétés permettant de configurer l'accès au lac de données pour la ressource de votre catalogue dans le catalogue de AWS Glue données.

- `CustomProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Propriétés clé-valeur supplémentaires pour le catalogue, telles que l'optimisation des statistiques des colonnes.

CatalogPropertiesOutput structure

Attributs de propriété qui incluent les propriétés de configuration de la ressource du catalogue.

Champs

- `DataLakeAccessProperties` – Un objet [DataLakeAccessPropertiesOutput](#).

`DataLakeAccessProperties` Objet doté de propriétés d'entrée permettant de configurer l'accès au lac de données pour les ressources de votre catalogue dans le catalogue de AWS Glue données.

- `CustomProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Propriétés clé-valeur supplémentaires pour le catalogue, telles que l'optimisation des statistiques des colonnes.

DataLakeAccessProperties structure

Entrez des propriétés pour configurer l'accès au lac de données pour la ressource de votre catalogue dans le catalogue de AWS Glue données.

Champs

- `DataLakeAccess` – Booléen.

Active ou désactive l'accès aux lacs de données pour les applications Apache Spark qui accèdent aux bases de données Amazon Redshift dans le catalogue de données à partir d'un moteur autre que Redshift, tel qu'Amazon Athena, Amazon EMR ou ETL. AWS Glue

- `DataTransferRole` – Chaîne UTF-8, correspondant au [Custom string pattern #51](#).

Rôle qui sera assumé par le transfert AWS Glue des données into/out du bucket intermédiaire lors d'une requête.

- `KmsKey` – Chaîne UTF-8.

Une clé de chiffrement qui sera utilisée pour le bucket intermédiaire qui sera créé avec le catalogue.

- `CatalogType` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Spécifie un type de catalogue fédéré pour la ressource de catalogue native. Le type actuellement pris en charge est `aws:redshift`.

DataLakeAccessPropertiesOutput structure

Les propriétés de sortie de la configuration d'accès au lac de données pour votre ressource de catalogue dans le catalogue de AWS Glue données.

Champs

- `DataLakeAccess` – Booléen.

Active ou désactive l'accès au lac de données pour les applications Apache Spark qui accèdent aux bases de données Amazon Redshift dans le catalogue de données.

- `DataTransferRole` – Chaîne UTF-8, correspondant au [Custom string pattern #51](#).

Rôle qui sera assumé par le transfert AWS Glue des données into/out du bucket intermédiaire lors d'une requête.

- `KmsKey` – Chaîne UTF-8.

Une clé de chiffrement qui sera utilisée pour le bucket intermédiaire qui sera créé avec le catalogue.

- `ManagedWorkgroupName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de calcul Redshift Serverless géré créé pour votre ressource de catalogue.

- `ManagedWorkgroupStatus` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

État du calcul Redshift Serverless géré.

- `RedshiftDatabaseName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la ressource de base de données Redshift par défaut dans le calcul géré.

- **StatusMessage** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Message qui fournit des informations plus détaillées sur l'état du groupe de travail géré.

- **CatalogType** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Spécifie un type de catalogue fédéré pour la ressource de catalogue native. Le type actuellement pris en charge est `aws:redshift`.

FederatedCatalog structure

Catalogue qui pointe vers une entité extérieure au catalogue AWS Glue de données.

Champs

- **Identifier** – Chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets, correspondant au [Single-line string pattern](#).

Identifiant unique pour le catalogue fédéré.

- **ConnectionName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la connexion à une source de données externe, par exemple un catalogue fédéré Redshift.

- **ConnectionType** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Type de connexion utilisé pour accéder au catalogue fédéré, spécifiant le protocole ou la méthode de connexion à la source de données externe.

Opérations

- [CreateCatalog action \(Python : create_catalog\)](#)
- [UpdateCatalog action \(Python : update_catalog\)](#)
- [DeleteCatalog action \(Python : supprimer_catalogue\)](#)
- [GetCatalog action \(Python : get_catalog\)](#)

- [GetCatalogs action \(Python : get_catalogs\)](#)

CreateCatalog action (Python : create_catalog)

Crée un nouveau catalogue dans le catalogue AWS Glue de données.

Demande

- Name— Obligatoire : chaîne UTF-8, d'au moins 1 ou plus de 64 octets, correspondant au. [Custom string pattern #25](#)

Nom du catalogue à créer.

- CatalogInput – Obligatoire : un objet [CatalogInput](#).

CatalogInputObjet qui définit les métadonnées du catalogue.

- Tags – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Un tableau cartographique de paires clé-valeur, pas plus de 50 paires. Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets. Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets. Les tags que vous attribuez au catalogue.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- InvalidInputException
- AlreadyExistsException
- ResourceNumberLimitExceededException
- InternalServiceException
- OperationTimeoutException
- GlueEncryptionException

- ConcurrentModificationException
- AccessDeniedException
- EntityNotFoundException
- FederatedResourceAlreadyExistsException
- FederationSourceException

UpdateCatalog action (Python : update_catalog)

Met à jour les propriétés d'un catalogue existant dans le catalogue de AWS Glue données.

Demande

- CatalogId – Obligatoire : Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue.

- CatalogInput – Obligatoire : un objet [CatalogInput](#).

CatalogInputObjet spécifiant les nouvelles propriétés d'un catalogue existant.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- EntityNotFoundException
- InvalidInputException
- InternalServiceException
- OperationTimeoutException
- GlueEncryptionException
- ConcurrentModificationException
- AccessDeniedException
- FederationSourceException

DeleteCatalog action (Python : supprimer_catalogue)

Supprime le catalogue spécifié du catalogue de AWS Glue données.

Une fois cette opération terminée, vous n'avez plus accès aux bases de données, aux tables (ni à toutes les versions de tables et partitions susceptibles d'appartenir aux tables) ni aux fonctions définies par l'utilisateur dans le catalogue supprimé. AWS Glue supprime ces ressources « orphelines » de manière asynchrone en temps opportun, à la discrétion du service.

Pour garantir la suppression immédiate de toutes les ressources associées avant d'appeler l'DeleteCatalogopération, utilisez DeleteTableVersion DeletePartition (ou BatchDeleteTableVersionBatchDeletePartition), DeleteTable (ouBatchDeleteTable), (ou) DeleteUserDefinedFunction et DeleteDatabase supprimez toutes les ressources appartenant au catalogue.

Demande

- CatalogId – Obligatoire : Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- EntityNotFoundException
- InvalidInputException
- InternalServiceException
- OperationTimeoutException
- GlueEncryptionException
- ConcurrentModificationException
- AccessDeniedException
- FederationSourceException

GetCatalog action (Python : get_catalog)

Nom du catalogue à récupérer. Tout doit être en minuscules.

Demande

- `CatalogId` – Obligatoire : Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue parent dans lequel réside le catalogue. Si aucun numéro n'est fourni, le numéro de AWS compte est utilisé par défaut.

Réponse

- `Catalog` – Un objet [Catalogue](#).

Un objet `Catalog`. Définition du catalogue spécifié dans le catalogue de AWS Glue données.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `FederationSourceException`
- `FederationSourceRetryableException`

GetCatalogs action (Python : get_catalogs)

Récupère tous les catalogues définis dans un catalogue dans le catalogue de AWS Glue données. Pour un cas d'utilisation d'un catalogue fédéré par Redshift, cette opération renvoie la liste des catalogues mappés aux bases de données Redshift dans le catalogue d'espaces de noms Redshift.

Demande

- `ParentCatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue parent dans lequel réside le catalogue. Si aucun numéro n'est fourni, le numéro de AWS compte est utilisé par défaut.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Le nombre maximum de catalogues à renvoyer en une seule réponse.

- `Recursive` – Booléen.

S'il faut répertorier tous les catalogues de la hiérarchie des catalogues, en commençant par le `ParentCatalogId`. La valeur par défaut est `false`. Lorsque `true`, tous les objets du catalogue de la `ParentCatalogId` hiérarchie sont énumérés dans la réponse.

- `IncludeRoot` – Booléen.

Indique s'il faut répertorier le catalogue par défaut dans le compte et dans la région dans la réponse. La valeur par défaut est `false`. Quand `true` et `ParentCatalogId = NULL` | `AWS Account ID`, tous les catalogues et le catalogue par défaut sont énumérés dans la réponse.

Lorsque le `n'ParentCatalogId` est pas égal à null et que cet attribut est passé sous la forme `false` ou `true`, un `InvalidInputException` est émis.

Réponse

- `CatalogList` – Obligatoire : Un tableau d'objets [Catalogue](#).

Tableau d'objets `Catalog`. Liste des `Catalog` objets du catalogue parent spécifié.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation pour la pagination de la liste des jetons renvoyés, renvoyé si le segment actuel de la liste n'est pas le dernier.

Erreurs

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `FederationSourceException`
- `FederationSourceRetryableException`

API d'une base de données

L'API de base de données décrit les types de données d'une base de données et comprend l'API permettant de créer, supprimer, localiser, mettre à jour et répertorier des bases de données.

Types de données

- [Structure Database](#)
- [DatabaseInput structure](#)
- [PrincipalPermissions structure](#)
- [DataLakePrincipal structure](#)
- [DatabaseIdentifier structure](#)
- [FederatedDatabase structure](#)

Structure Database

L'objet Database représente un groupement logique de tables pouvant résider dans un metastore Hive ou un SGBDR.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données. Pour des raisons de compatibilité avec Hive, ce nom est converti en minuscules lors de son stockage.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la base de données.

- **LocationUri** – Identificateur de ressource uniforme (URI), d'une longueur comprise entre 1 et 1024 octets, correspondant au [URI address multi-line string pattern](#).

Emplacement de la base de données (par exemple, un chemin HDFS).

- **Parameters** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Ces paires clé-valeur définissent les paramètres et les propriétés de la base de données.

- **CreateTime** – Horodatage.

Heure à laquelle la base de données de métadonnées a été créée dans le catalogue.

- **CreateTableDefaultPermissions** – Un tableau d'objets [PrincipalPermissions](#).

Crée un ensemble d'autorisations par défaut sur le tableau pour les principaux. Utilisé par AWS Lake Formation. Non utilisé dans le cours normal des AWS Glue opérations.

- **TargetDatabase** – Un objet [DatabaseIdentifier](#).

Structure `DatabaseIdentifier` qui décrit une base de données cible pour la liaison de ressources.

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la base de données.

- **FederatedDatabase** – Un objet [FederatedDatabase](#).

Une structure `FederatedDatabase` qui fait référence à une entité extérieure à AWS Glue Data Catalog.

Databaselnput structure

Structure utilisée pour créer ou mettre à jour une base de données.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données. Pour des raisons de compatibilité avec Hive, ce nom est converti en minuscules lors de son stockage.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la base de données.

- **LocationUri** – Identificateur de ressource uniforme (URI), d'une longueur comprise entre 1 et 1024 octets, correspondant au [URI address multi-line string pattern](#).

Emplacement de la base de données (par exemple, un chemin HDFS).

- **Parameters** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Ces paires clé-valeur définissent les paramètres et les propriétés de la base de données.

Ces paires clé-valeur définissent les paramètres et les propriétés de la base de données.

- **CreateTableDefaultPermissions** – Un tableau d'objets [PrincipalPermissions](#).

Crée un ensemble d'autorisations par défaut sur le tableau pour les principaux. Utilisé par AWS Lake Formation. Non utilisé dans le cours normal des AWS Glue opérations.

- **TargetDatabase** – Un objet [DatabaseIdentifier](#).

Structure `DatabaseIdentifier` qui décrit une base de données cible pour la liaison de ressources.

- **FederatedDatabase** – Un objet [FederatedDatabase](#).

Une structure `FederatedDatabase` qui fait référence à une entité extérieure à AWS Glue Data Catalog.

PrincipalPermissions structure

Autorisations accordées à un principal.

Champs

- `Principal` – Un objet [DataLakePrincipal](#).

Principal à qui les autorisations sont accordées.

- `Permissions` – Tableau de chaînes UTF-8.

Autorisations accordées au principal.

DataLakePrincipal structure

Le AWS Lake Formation directeur.

Champs

- `DataLakePrincipalIdentifier` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets.

Un identifiant pour le AWS Lake Formation principal.

Databaselfentifier structure

Structure qui décrit une base de données cible pour la liaison de ressources.

Champs

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la base de données.

- `DatabaseName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue.

- **Region** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Région de la base de données cible.

FederatedDatabase structure

Une base de données qui pointe vers une entité extérieure à AWS Glue Data Catalog.

Champs

- **Identifier** – Chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets, correspondant au [Single-line string pattern](#).

Un identifiant unique pour la base de données fédérée.

- **ConnectionName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la connexion au métastore externe.

- **ConnectionType** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Type de connexion utilisé pour accéder à la base de données fédérée, tel que JDBC, ODBC ou d'autres protocoles de connexion pris en charge.

Opérations

- [CreateDatabase action \(Python : créer_base de données\)](#)
- [UpdateDatabase action \(Python : update_database\)](#)
- [DeleteDatabase action \(Python : supprimer_base de données\)](#)
- [GetDatabase action \(Python : get_database\)](#)
- [GetDatabases action \(Python : get_databases\)](#)

CreateDatabase action (Python : créer_base de données)

Crée une nouvelle base de données dans un catalogue de données.

Demande

- CatalogId – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel créer la base de données. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- DatabaseInput – Obligatoire : un objet [DatabaseInput](#).

Métadonnées pour la base de données.

- Tags – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Les balises que vous attribuez à la base de données.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- InvalidInputException
- AlreadyExistsException
- ResourceNumberLimitExceededException
- InternalServiceException
- OperationTimeoutException
- GlueEncryptionException
- ConcurrentModificationException
- FederatedResourceAlreadyExistsException
- FederationSourceException

- `FederationSourceRetryableException`

UpdateDatabase action (Python : `update_database`)

Met à jour une définition de base de données existante dans un catalogue de données.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la base de données de métadonnées. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données à mettre à jour dans le catalogue. Pour la compatibilité Hive, ce nom est converti en minuscules.

- `DatabaseInput` – Obligatoire : un objet [DatabaseInput](#).

Objet `DatabaseInput` spécifiant la nouvelle définition de la base de données de métadonnées dans le catalogue.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ConcurrentModificationException`
- `FederationSourceException`

- `FederationSourceRetryableException`
- `AlreadyExistsException`

DeleteDatabase action (Python : `supprimer_base` de données)

Supprime une base de données spécifiée d'un catalogue de données.

Note

Une fois cette opération terminée, vous n'avez plus accès aux tables (ni à toutes les versions de tables et partitions susceptibles d'appartenir aux tables) ni aux fonctions définies par l'utilisateur dans la base de données supprimée. AWS Glue supprime ces ressources « orphelines » de manière asynchrone en temps opportun, à la discrétion du service. Pour garantir la suppression immédiate de toutes les ressources connexes, avant d'appeler `DeleteDatabase`, utilisez `DeleteTableVersion` ou `BatchDeleteTableVersion`, `DeletePartition` ou `BatchDeletePartition`, `DeleteUserDefinedFunction`, et `DeleteTable` ou `BatchDeleteTable` pour supprimer les ressources appartenant à la base de données.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la base de données. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données à supprimer. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- EntityNotFoundException
- InvalidInputException
- InternalServiceException
- OperationTimeoutException
- ConcurrentModificationException
- FederationSourceException
- FederationSourceRetryableException

GetDatabase action (Python : get_database)

Extrait la définition d'une base de données spécifiée.

Demande

- CatalogId – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la base de données. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom la base de données à extraire. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

Réponse

- Database – Un objet [Base de données](#).

Définition de la base de données spécifiée dans le catalogue de données.

Erreurs

- InvalidInputException
- EntityNotFoundException

- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `FederationSourceException`
- `FederationSourceRetryableException`

GetDatabases action (Python : `get_databases`)

Extrait toutes les bases de données définies dans un catalogue de données donnée.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données à partir duquel extraire Databases. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

- `MaxResults` – Nombre (entier), compris entre 1 et 100.

Nombre maximum de bases de données renvoyées par réponse.

- `ResourceShareType` – Chaîne UTF-8 (valeurs valides : `FOREIGN` | `ALL` | `FEDERATED`).

Permet de spécifier que vous souhaitez répertorier les bases de données partagées avec votre compte. Les valeurs autorisées sont `FEDERATED`, `FOREIGN` ou `ALL`.

- Si la valeur est définie sur `FEDERATED`, la liste des bases de données fédérées (référénçant une entité externe) partagées avec votre compte sera affichée.
- Si défini sur `FOREIGN`, répertorie les bases de données partagées avec votre compte.
- Si défini sur `ALL`, répertorie les bases de données partagées avec votre compte, ainsi que les bases de données dans votre compte local.
- `AttributesToGet` – Tableau de chaînes UTF-8.

Spécifie les champs de base de données renvoyés par l'`GetDatabases`appel. Ce paramètre n'accepte pas une liste vide. La demande doit inclure le `NAME`.

Réponse

- DatabaseList – Obligatoire : Un tableau d'objets [Base de données](#).

Liste d'objets Database à partir du catalogue spécifié.

- NextToken – Chaîne UTF-8.

Jeton de continuation pour la pagination de la liste des jetons renvoyés, renvoyé si le segment actuel de la liste n'est pas le dernier.

Erreurs

- InvalidInputException
- InternalServiceException
- OperationTimeoutException
- GlueEncryptionException
- EntityNotFoundException
- FederationSourceException
- FederationSourceRetryableException

API de table

L'API de tableau décrit les types de données et les opérations associés aux tableaux.

Types de données

- [Structure de table](#)
- [TableInput structure](#)
- [FederatedTable structure](#)
- [Structure de colonne](#)
- [StorageDescriptor structure](#)
- [SchemaReference structure](#)
- [SerDeInfo structure](#)
- [Structure de tri](#)
- [SkewedInfo structure](#)

- [TableVersion structure](#)
- [TableError structure](#)
- [TableVersionError structure](#)
- [SortCriterion structure](#)
- [TableIdentifier structure](#)
- [KeySchemaElement structure](#)
- [PartitionIndex structure](#)
- [PartitionIndexDescriptor structure](#)
- [BackfillError structure](#)
- [IcebergInput structure](#)
- [OpenTableFormatInput structure](#)
- [ViewDefinition structure](#)
- [ViewDefinitionInput structure](#)
- [ViewRepresentation structure](#)
- [ViewRepresentationInput structure](#)
- [UpdateOpenTableFormatInput structure](#)
- [UpdateIcebergInput structure](#)
- [CreateIcebergTableInput structure](#)
- [UpdateIcebergTableInput structure](#)
- [IcebergSortOrder structure](#)
- [IcebergSortField structure](#)
- [IcebergPartitionSpec structure](#)
- [IcebergPartitionField structure](#)
- [IcebergSchema structure](#)
- [IcebergStructField structure](#)
- [IcebergTableUpdate structure](#)

Structure de table

Représente un ensemble de données connexes organisées en colonnes et en lignes.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- **DatabaseName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données où résident les métadonnées de table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la table.

- **Owner** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Propriétaire de la table.

- **CreateTime** – Horodatage.

Date de création de la définition de table dans le catalogue de données.

- **UpdateTime** – Horodatage.

Date de la dernière mise à jour de la table.

- **LastAccessTime** – Horodatage.

Date du dernier accès à la table. Cette information est généralement extraite de HDFS et peut ne pas être fiable.

- **LastAnalyzedTime** – Horodatage.

Dernière date de calcul des statistiques de colonne pour cette table.

- **Retention** – Nombre (entier), pas plus qu'Aucun.

Durée de conservation de la table.

- **StorageDescriptor** – Un Objet [StorageDescriptor](#).

Descripteur de stockage contenant des informations sur le stockage physique de la table.

- **PartitionKeys** – Un tableau d'objets [Colonne](#).

Liste de colonnes par laquelle la table est partitionnée. Seuls les types primitifs sont pris en charge en tant que clés de partition.

Lorsque vous créez un tableau utilisé par Amazon Athena et que vous ne spécifiez pas de `partitionKeys`, vous devez au moins régler la valeur de `partitionKeys` à une liste vide. Par exemple :

```
"PartitionKeys": []
```

- **ViewOriginalText** – Chaîne UTF-8, d'une longueur maximale de 409 600 octets.

Inclus pour la compatibilité avec Apache Hive. Non utilisé dans le cours normal des AWS Glue opérations. Si la table est une `VIRTUAL_VIEW`, une certaine Athena configuration codée en base64.

- **ViewExpandedText** – Chaîne UTF-8, d'une longueur maximale de 409 600 octets.

Inclus pour la compatibilité avec Apache Hive. Non utilisé dans le cours normal des AWS Glue opérations.

- **TableType** – Chaîne UTF-8, d'une longueur maximale de 255 octets.

Type de cette table. AWS Glue créera des tables avec le `EXTERNAL_TABLE` type. D'autres services, tels que Athena, peuvent créer des tables avec des types de tables supplémentaires.

AWS Glue types de tables associés :

`EXTERNAL_TABLE`

Attribut compatible avec Hive : indique une table non gérée par Hive.

`GOVERNED`

Utilisé par AWS Lake Formation. Le catalogue AWS Glue de données comprend `GOVERNED`.

- **Parameters** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Ces paires clé-valeur définissent les propriétés associées à la table.

- **CreatedBy** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Personne ou entité qui a créé la table.

- **IsRegisteredWithLakeFormation** – Booléen.

Indique si la table a été enregistrée auprès de AWS Lake Formation.

- **TargetTable** – Un objet [TableIdentifier](#).

Structure `TableIdentifier` qui décrit une table cible pour la liaison de ressources.

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la table.

- **VersionId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de la version de tableau.

- **FederatedTable** – Un objet [FederatedTable](#).

Une structure `FederatedTable` qui fait référence à une entité extérieure à AWS Glue Data Catalog.

- **ViewDefinition** – Un objet [ViewDefinition](#).

Structure contenant toutes les informations qui définissent la vue, y compris le ou les dialectes de la vue et de la requête.

- **IsMultiDialectView** – Booléen.

Spécifie si la vue prend en charge les dialectes SQL d'un ou de plusieurs moteurs de requête différents et peut donc être lue par ces moteurs.

TableInput structure

Structure utilisé pour définir une table.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table. Pour des raisons de compatibilité avec Hive, ce nom est converti en minuscules lors de son stockage.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la table.

- **Owner** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Propriétaire de la table. Inclus pour la compatibilité avec Apache Hive. Non utilisé dans le cours normal des AWS Glue opérations.

- **LastAccessTime** – Horodatage.

Date du dernier accès à la table.

- **LastAnalyzedTime** – Horodatage.

Dernière date de calcul des statistiques de colonne pour cette table.

- **Retention** – Nombre (entier), pas plus qu'Aucun.

Durée de conservation de la table.

- **StorageDescriptor** – Un Objet [StorageDescriptor](#).

Descripteur de stockage contenant des informations sur le stockage physique de la table.

- **PartitionKeys** – Un tableau d'objets [Colonne](#).

Liste de colonnes par laquelle la table est partitionnée. Seuls les types primitifs sont pris en charge en tant que clés de partition.

Lorsque vous créez un tableau utilisé par Amazon Athena et que vous ne spécifiez pas de `partitionKeys`, vous devez au moins régler la valeur de `partitionKeys` à une liste vide. Par exemple :

```
"PartitionKeys": []
```

- `ViewOriginalText` – Chaîne UTF-8, d'une longueur maximale de 409 600 octets.

Inclus pour la compatibilité avec Apache Hive. Non utilisé dans le cours normal des AWS Glue opérations. Si la table est une `VIRTUAL_VIEW`, une certaine Athena configuration codée en base64.

- `ViewExpandedText` – Chaîne UTF-8, d'une longueur maximale de 409 600 octets.

Inclus pour la compatibilité avec Apache Hive. Non utilisé dans le cours normal des AWS Glue opérations.

- `TableType` – Chaîne UTF-8, d'une longueur maximale de 255 octets.

Type de cette table. AWS Glue créera des tables avec le `EXTERNAL_TABLE` type. D'autres services, tels que Athena, peuvent créer des tables avec des types de tables supplémentaires.

AWS Glue types de tables associés :

`EXTERNAL_TABLE`

Attribut compatible avec Hive : indique une table non gérée par Hive.

`GOVERNED`

Utilisé par AWS Lake Formation. Le catalogue AWS Glue de données comprend `GOVERNED`.

- `Parameters` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Ces paires clé-valeur définissent les propriétés associées à la table.

- `TargetTable` – Un objet [TableIdentifier](#).

Structure `TableIdentifier` qui décrit une table cible pour la liaison de ressources.

- `ViewDefinition` – Un objet [ViewDefinitionInput](#).

Structure contenant toutes les informations qui définissent la vue, y compris le ou les dialectes de la vue et de la requête.

FederatedTable structure

Une table qui pointe vers une entité extérieure à AWS Glue Data Catalog.

Champs

- **Identifier** – Chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets, correspondant au [Single-line string pattern](#).

Un identifiant unique pour la table fédérée.

- **DatabaseIdentifier** – Chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets, correspondant au [Single-line string pattern](#).

Un identifiant unique pour la base de données fédérée.

- **ConnectionName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la connexion au métastore externe.

- **ConnectionType** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Type de connexion utilisé pour accéder à la table fédérée, spécifiant le protocole ou la méthode de connexion à la source de données externe.

Structure de colonne

Colonne d'une Table.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de l'Column.

- **Type** – Chaîne UTF-8, d'une longueur maximale de 131 072 octets, correspondant au [Single-line string pattern](#).

Le type de données de Column.

- **Comment** – Chaîne de commentaire, d'une longueur maximale de 255 octets, correspondant au [Single-line string pattern](#).

Commentaire au format de texte libre.

- **Parameters** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Ces paires clé-valeur définissent les propriétés associées à la colonne.

StorageDescriptor structure

Décrit le stockage physique des données de table.

Champs

- **Columns** – Un tableau d'objets [Colonne](#).

Liste des Columns de la table.

- **Location** – Chaîne de localisation, d'une longueur maximale de 2 056 octets, correspondant au [URI address multi-line string pattern](#).

Emplacement physique de la table. Par défaut, il prend la forme de l'emplacement de entrepôt, suivie de l'emplacement de la base de données dans l'entrepôt, suivi du nom de la table.

- **AdditionalLocations** – Tableau de chaînes UTF-8.

Liste des emplacements pointant vers le chemin d'accès où se trouve une table Delta.

- **InputFormat** – Chaîne de format, d'une longueur maximale de 128 octets, correspondant au [Single-line string pattern](#).

Format d'entrée : `SequenceFileInputFormat` (binaire) ou `TextInputFormat` ou format personnalisé.

- **OutputFormat** – Chaîne de format, d'une longueur maximale de 128 octets, correspondant au [Single-line string pattern](#).

Format de sortie : `SequenceFileOutputFormat` (binaire) ou `IgnoreKeyTextOutputFormat` ou format personnalisé.

- `Compressed` – Booléen.

`True` si les données de la table sont compressées ou `False` si elles ne le sont pas.

- `NumberOfBuckets` – Nombre (entier).

Doit être spécifié si la table contient des colonnes de dimension.

- `SerdeInfo` – Un objet [SerDeInfo](#).

Les serialization/deserialization (SerDe) informations.

- `BucketColumns` – Tableau de chaînes UTF-8.

Liste de colonnes de regroupement de réducteur, de colonnes de clustérisation et de colonnes de mise en compartiment de la table.

- `SortColumns` – Un tableau d'objets [Ordre](#).

Liste spécifiant l'ordre de tri de chaque compartiment de la table.

- `Parameters` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Propriétés fournies par l'utilisateur sous la forme clé-valeur.

- `SkewedInfo` – Un objet [SkewedInfo](#).

Informations concernant les valeurs qui apparaissent fréquemment dans une colonne (valeurs asymétriques).

- `StoredAsSubDirectories` – Booléen.

`True` si les données de la table sont stockées dans les sous-répertoires ou `False` dans le cas contraire.

- `SchemaReference` – Un objet [SchemaReference](#).

Objet qui fait référence à un schéma stocké dans le registre des AWS Glue schémas.

Lors de la création d'une table, vous pouvez transmettre une liste vide de colonnes pour le schéma et plutôt utiliser une référence de schéma.

SchemaReference structure

Objet qui fait référence à un schéma stocké dans le registre des AWS Glue schémas.

Champs

- **SchemaId** – Un objet [Schemald](#).

Structure qui contient des champs d'identité de schéma. Ceci ou **SchemaVersionId** doit être fourni.

- **SchemaVersionId** – Obligatoire : chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

ID unique affecté à une version du schéma. Ceci ou **SchemaId** doit être fourni.

- **SchemaVersionNumber** – Nombre (long), compris entre 1 et 100 000.

Numéro de version du schéma.

SerDeInfo structure

Informations sur un serialization/deserialization programme (SerDe) qui sert d'extracteur et de chargeur.

Champs

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du SerDe.

- **SerializationLibrary** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Généralement, la classe qui implémente le SerDe. Par exemple :

`org.apache.hadoop.hive.serde2.columnar.ColumnarSerDe`.

- **Parameters** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Ces paires clé-valeur définissent les paramètres d'initialisation pour. SerDe

Structure de tri

Indique l'ordre de tri d'une colonne triée.

Champs

- `Column` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la colonne.

- `SortOrder` – Obligatoire : Nombre (entier), inférieur ou égal à 1.

Indique que la colonne est triée en ordre croissant (`= 1`) ou en ordre décroissant (`= 0`).

SkewedInfo structure

Spécifie les valeurs biaisées d'une table. Les valeurs biaisées sont celles qui se produisent à très haute fréquence.

Champs

- `SkewedColumnNames` – Tableau de chaînes UTF-8.

Liste des noms de colonnes qui contiennent des valeurs biaisées.

- `SkewedColumnValues` – Tableau de chaînes UTF-8.

Liste des valeurs qui apparaissent si fréquemment qu'elles sont considérées comme biaisées.

- `SkewedColumnValueLocationMaps` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Mappage de valeurs biaisées avec les colonnes qui les contiennent.

TableVersion structure

Spécifie une version d'une table.

Champs

- `Table` – Un objet [Tableau](#).

Table en question

- `VersionId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Valeur d'ID qui identifie cette version de table. Un `VersionId` est une représentation de chaîne d'un nombre entier. Chaque version est incrémentée par 1.

TableError structure

Enregistrement d'erreur pour les opérations de table.

Champs

- `TableName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- `ErrorDetail` – Un objet [ErrorDetail](#).

Détails relatifs à l'erreur.

TableVersionError structure

Enregistrement d'erreur pour les opérations de version table.

Champs

- `TableName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table en question.

- `VersionId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Valeur d'ID de la version en question. Un `VersionId` est une représentation de chaîne d'un nombre entier. Chaque version est incrémentée par 1.

- `ErrorDetail` – Un objet [ErrorDetail](#).

Détails relatifs à l'erreur.

SortCriterion structure

Spécifie un champ selon lequel trier et un ordre de tri.

Champs

- `FieldName`— Chaîne de valeurs d'une longueur d'au moins 1 ou de 1 024 octets.

Nom du champ sur lequel trier.

- `Sort` – Chaîne UTF-8 (valeurs valides : `ASC="ASCENDING"` | `DESC="DESCENDING"`).

Tri croissant ou décroissant.

TableIdentifier structure

Structure qui décrit une table cible pour la liaison de ressources.

Champs

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la table.

- `DatabaseName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue qui contient la table cible.

- Name – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table cible.

- Region – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Région de la table cible.

KeySchemaElement structure

Une paire de clés de partition composée d'un nom et d'un type.

Champs

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom d'une clé de partition.

- Type – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 131 072 octets, correspondant au [Single-line string pattern](#).

Type d'une clé de partition.

PartitionIndex structure

Structure pour un index de partition.

Champs

- Keys – Obligatoire : Tableau de chaînes UTF-8, au moins 1 chaîne.

Les clés de l'index de partition.

- IndexName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'index de partition.

PartitionIndexDescriptor structure

Descripteur d'un index de partition dans une table.

Champs

- **IndexName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'index de partition.

- **Keys** – Obligatoire : Tableau d'objets [KeySchemaElement](#), au moins 1 structure.

Liste d'une ou plusieurs clés, sous forme de structures `KeySchemaElement`, pour l'index de partition.

- **IndexStatus** – Obligatoire : Chaîne UTF-8 (valeurs valides : `CREATING` | `ACTIVE` | `DELETING` | `FAILED`).

Statut de l'index de partition.

Les statuts possibles sont les suivants :

- **CRÉATION** : l'index est en cours de création. Lorsqu'un index est dans un état `CRÉATION`, l'index ou sa table ne peut pas être supprimé.
- **ACTIVE** : la création de l'index a réussi.
- **ÉCHEC** : la création de l'index a échoué.
- **SUPPRESSION** : l'index est supprimé de la liste des index.
- **BackfillErrors** – Un tableau d'objets [BackfillError](#).

Liste d'erreurs qui peuvent se produire lors de l'enregistrement d'index de partition pour une table existante.

BackfillError structure

Liste d'erreurs qui peuvent se produire lors de l'enregistrement d'index de partition pour une table existante.

Ces erreurs donnent les détails sur la raison pour laquelle un enregistrement d'index a échoué et fournissent un nombre limité de partitions dans la réponse, de sorte que vous pouvez corriger les

partitions défaillantes et essayer d'enregistrer à nouveau l'index. Les erreurs les plus courantes pouvant se produire sont classées comme suit :

- `EncryptedPartitionError`: Les partitions sont cryptées.
- `InvalidPartitionTypeDataError`: La valeur de la partition ne correspond pas au type de données de cette colonne de partition.
- `MissingPartitionValueError`: Les partitions sont cryptées.
- `UnsupportedPartitionCharacterError`: Les caractères contenus dans la valeur de partition ne sont pas pris en charge. Par exemple : U+0000, U+0001, U+0002.
- `InternalError`: Toute erreur qui n'appartient pas à d'autres codes d'erreur.

Champs

- `Code` – Chaîne UTF-8 (valeurs valides : `ENCRYPTED_PARTITION_ERROR` | `INTERNAL_ERROR` | `INVALID_PARTITION_TYPE_DATA_ERROR` | `MISSING_PARTITION_VALUE_ERROR` | `UNSUPPORTED_PARTITION_CHARACTER_ERROR`).

Code d'erreur correspondant à une erreur survenue lors de l'enregistrement d'index de partition pour une table existante.

- `Partitions` – Un tableau d'objets [PartitionValueList](#).

Liste d'un nombre limité de partitions dans la réponse.

IcebergInput structure

Une structure qui définit une table de métadonnées Apache Iceberg à créer dans le catalogue.

Champs

- `MetadataOperation` – Obligatoire : Chaîne UTF-8 (valeurs valides : `CREATE`).

Une opération de métadonnées obligatoire. Ne peut être défini que sur `CREATE`.

- `Version` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

La version de table pour la table Iceberg. La valeur par défaut est 2.

- `CreateIcebergTableInput` – Un objet [CreateIcebergTableInput](#).

Les paramètres de configuration requis pour créer une nouvelle table Iceberg dans le catalogue de AWS Glue données, y compris les propriétés de la table et les spécifications des métadonnées.

OpenTableFormatInput structure

Une structure représentant un tableau au format ouvert.

Champs

- IcebergInput – Un objet [IcebergInput](#).

Spécifie une structure IcebergInput qui définit une table de métadonnées Apache Iceberg.

ViewDefinition structure

Structure contenant les détails des représentations.

Champs

- IsProtected – Booléen.

Vous pouvez définir cet indicateur sur true pour indiquer au moteur de ne pas transférer les opérations fournies par l'utilisateur dans le plan logique de la vue lors de la planification des requêtes. Cependant, le réglage de cet indicateur ne garantit pas que le moteur sera conforme. Reportez-vous à la documentation du moteur pour comprendre les garanties fournies, le cas échéant.

- Definer – chaîne UTF-8, d'une longueur comprise entre 20 et 2048 octets, correspondant au [Single-line string pattern](#).

Le définisseur d'une vue en SQL.

- SubObjects – Tableau de chaînes UTF-8, avec 10 chaînes maximum.

Liste des tables Amazon Resource Names (ARNs).

- Representations – tableau d'objets [ViewRepresentation](#), avec 1 structure minimum et 1 000 structures maximum.

Une liste de représentations.

ViewDefinitionInput structure

Structure contenant les détails relatifs à la création ou à la mise à jour d'une AWS Glue vue.

Champs

- `IsProtected` – Booléen.

Vous pouvez définir cet indicateur sur `true` pour indiquer au moteur de ne pas transférer les opérations fournies par l'utilisateur dans le plan logique de la vue lors de la planification des requêtes. Cependant, le réglage de cet indicateur ne garantit pas que le moteur sera conforme. Reportez-vous à la documentation du moteur pour comprendre les garanties fournies, le cas échéant.

- `Definer` – chaîne UTF-8, d'une longueur comprise entre 20 et 2048 octets, correspondant au [Single-line string pattern](#).

Le définisseur d'une vue en SQL.

- `Representations`— Un ensemble d'[ViewRepresentationInput](#) objets, composé d'au moins 1 ou de plus de 10 structures.

Liste de structures contenant le dialecte de la vue et la requête qui définit la vue.

- `SubObjects` – Tableau de chaînes UTF-8, avec 10 chaînes maximum.

Liste des tables de base ARNs qui constituent la vue.

ViewRepresentation structure

Structure qui contient le dialecte de la vue et la requête qui définit la vue.

Champs

- `Dialect` – Chaîne UTF-8 (valeurs valides : REDSHIFT | ATHENA | SPARK).

Le dialecte du moteur de requête.

- `DialectVersion` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets.

Version du dialecte du moteur de requête. Par exemple, 3.0.0.

- `ViewOriginalText` – Chaîne UTF-8, d'une longueur maximale de 409 600 octets.

La SELECT requête fournie par le client pendant CREATE VIEW DDL. Ce code SQL n'est pas utilisé lors d'une requête sur une vue (ViewExpandedText est utilisé à la place).

ViewOriginalText est utilisé dans les cas SHOW CREATE VIEW où les utilisateurs souhaitent voir la commande DDL d'origine qui a créé la vue.

- ViewExpandedText – Chaîne UTF-8, d'une longueur maximale de 409 600 octets.

Le code SQL développé pour la vue. Ce code SQL est utilisé par les moteurs lors du traitement d'une requête sur une vue. Les moteurs peuvent effectuer des opérations lors de la création de la vue pour la transformer ViewOriginalText en ViewExpandedText. Par exemple :

- Identifiants entièrement qualifiés : `SELECT * from table1 -> SELECT * from db1.table1`
- ValidationConnection – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la connexion à utiliser pour valider la représentation spécifique de la vue.

- IsStale – Booléen.

Les dialectes marqués comme périmés ne sont plus valides et doivent être mis à jour avant de pouvoir être interrogés dans leurs moteurs de requêtes respectifs.

ViewRepresentationInput structure

Structure contenant les détails d'une représentation pour mettre à jour ou créer une vue de Lake Formation.

Champs

- Dialect – Chaîne UTF-8 (valeurs valides : REDSHIFT | ATHENA | SPARK).

Paramètre qui indique le type de moteur d'une représentation spécifique.

- DialectVersion – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets.

Paramètre qui indique la version du moteur d'une représentation spécifique.

- ViewOriginalText – Chaîne UTF-8, d'une longueur maximale de 409 600 octets.

Chaîne qui représente la requête SQL d'origine qui décrit la vue.

- `ValidationConnection` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la connexion à utiliser pour valider la représentation spécifique de la vue.

- `ViewExpandedText` – Chaîne UTF-8, d'une longueur maximale de 409 600 octets.

Chaîne qui représente la requête SQL qui décrit la vue avec une ressource étendue ARNs

UpdateOpenTableFormatInput structure

Paramètres d'entrée pour la mise à jour des tables au format de table ouvertes dans AWS Glue Data Catalog, servant de wrapper pour les opérations de mise à jour spécifiques au format, telles qu'Apache Iceberg.

Champs

- `UpdateIcebergInput` – Un objet [UpdateIcebergInput](#).

Paramètres de mise à jour spécifiques à Apache Iceberg qui définissent les modifications de table à appliquer, notamment les modifications de schéma, les spécifications de partition et les propriétés de table.

UpdateIcebergInput structure

Paramètres d'entrée spécifiques à la mise à jour des tables Apache Iceberg dans le catalogue de AWS Glue données, contenant les opérations de mise à jour à appliquer à une table Iceberg existante.

Champs

- `UpdateIcebergTableInput` – Obligatoire : un objet [UpdateIcebergTableInput](#).

Les opérations de mise à jour spécifiques à appliquer à la table Iceberg, contenant une liste de mises à jour qui définissent le nouvel état de la table, y compris le schéma, les partitions et les propriétés.

CreateIcebergTableInput structure

Les paramètres de configuration requis pour créer une nouvelle table Iceberg dans le catalogue de AWS Glue données, y compris les propriétés de la table et les spécifications des métadonnées.

Champs

- **Location**— Obligatoire : chaîne de localisation, d'une longueur maximale de 2 056 octets, correspondant au [URI address multi-line string pattern](#).

Emplacement S3 où les données de la table Iceberg seront stockées.

- **Schema** – Obligatoire : un objet [IcebergSchema](#).

Définition du schéma qui spécifie la structure, les types de champs et les métadonnées de la table Iceberg.

- **PartitionSpec** – Un objet [IcebergPartitionSpec](#).

Spécification de partitionnement qui définit la manière dont les données de la table Iceberg seront organisées et partitionnées pour des performances de requête optimales.

- **WriteOrder** – Un objet [IcebergSortOrder](#).

Spécification de l'ordre de tri qui définit la manière dont les données doivent être ordonnées au sein de chaque partition afin d'optimiser les performances des requêtes.

- **Properties** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Paires clé-valeur contenant des propriétés de table supplémentaires et des paramètres de configuration pour la table Iceberg.

UpdateIcebergTableInput structure

Contient les opérations de mise à jour à appliquer à une table Iceberg existante dans le catalogue de AWS Glue données, définissant le nouvel état des métadonnées de la table.

Champs

- **Updates** – Obligatoire : Un tableau d'objets [IcebergTableUpdate](#).

Liste des opérations de mise à jour de table qui spécifient les modifications à apporter à la table Iceberg, notamment les modifications du schéma, les spécifications de partition et les propriétés de la table.

IcebergSortOrder structure

Définit la spécification de l'ordre de tri d'une table Iceberg, en déterminant comment les données doivent être ordonnées au sein des partitions afin d'optimiser les performances des requêtes.

Champs

- `OrderId` – Obligatoire : nombre (entier).

Identifiant unique pour cette spécification d'ordre de tri dans les métadonnées de la table Iceberg.

- `Fields` – Obligatoire : Un tableau d'objets [IcebergSortField](#).

La liste des champs et leur sens de tri qui définissent les critères de classement des données de la table Iceberg.

IcebergSortField structure

Définit un champ unique dans une spécification d'ordre de tri Iceberg, y compris le champ source, la transformation, le sens de tri et l'ordre des valeurs nulles.

Champs

- `SourceId` – Obligatoire : nombre (entier).

Identifiant du champ source issu du schéma de table sur lequel ce champ de tri est basé.

- `Transform` – Obligatoire : chaîne UTF-8.

Fonction de transformation appliquée au champ source avant le tri, telle que identity, bucket ou truncate.

- `Direction` – Obligatoire : Chaîne UTF-8 (valeurs valides : asc="ASC" | desc="DESC").

Direction de tri de ce champ, ascendante ou descendante.

- `NullOrder` – Obligatoire : Chaîne UTF-8 (valeurs valides : nulls-first="NULLS_FIRST" | nulls-last="NULLS_LAST").

Comportement du classement des valeurs nulles dans ce champ, spécifiant si les valeurs nulles doivent apparaître en premier ou en dernier dans l'ordre de tri.

IcebergPartitionSpec structure

Définit la spécification de partitionnement d'une table Iceberg, en déterminant comment les données de la table seront organisées et partitionnées pour des performances de requête optimales.

Champs

- **Fields** – Obligatoire : Un tableau d'objets [IcebergPartitionField](#).

Liste des champs de partition qui définissent la manière dont les données de la table doivent être partitionnées, y compris les champs source et leurs transformations.

- **SpecId** – Nombre (entier).

Identifiant unique de cette spécification de partition dans l'historique des métadonnées de la table Iceberg.

IcebergPartitionField structure

Définit un champ de partition unique dans une spécification de partition Iceberg, y compris le champ source, la fonction de transformation, le nom de partition et l'identifiant unique.

Champs

- **SourceId** – Obligatoire : nombre (entier).

Identifiant du champ source issu du schéma de table sur lequel ce champ de partition est basé.

- **Transform** – Obligatoire : chaîne UTF-8.

Fonction de transformation appliquée au champ source pour créer la partition, telle que l'identité, le compartiment, la troncation, l'année, le mois, le jour ou l'heure.

- **Name** – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 1024 octets, correspondant au [Single-line string pattern](#).

Nom du champ de partition tel qu'il apparaîtra dans la structure de la table partitionnée.

- **FieldId** – Nombre (entier).

Identifiant unique attribué à ce champ de partition dans la spécification de partition de la table Iceberg.

IcebergSchema structure

Définit la structure du schéma d'une table Iceberg, y compris les définitions de champs, les types de données et les métadonnées du schéma.

Champs

- **SchemaId** – Nombre (entier).

Identifiant unique de cette version de schéma dans l'historique d'évolution du schéma de la table Iceberg.

- **IdentifierFieldIds**— Tableau d'entiers 32 bits signés.

Liste des identificateurs de champ qui identifient de manière unique les enregistrements de la table, utilisés pour les opérations au niveau des lignes et la déduplication.

- **Type** – Chaîne UTF-8 (valeurs valides : `struct="STRUCT"`).

Type de racine de la structure du schéma, généralement « struct » pour les schémas de table Iceberg.

- **Fields** – Obligatoire : Un tableau d'objets [IcebergStructField](#).

Liste des définitions de champs qui constituent le schéma de table, y compris les noms, les types et les métadonnées des champs.

IcebergStructField structure

Définit un champ unique dans un schéma de table Iceberg, y compris son identifiant, son nom, son type de données, son caractère nul et sa documentation.

Champs

- **Id** – Obligatoire : nombre (entier).

Identifiant unique attribué à ce champ dans le schéma de table Iceberg, utilisé pour l'évolution du schéma et le suivi des champs.

- **Name – Obligatoire** : chaîne UTF-8, d'une longueur comprise entre 1 et 1024 octets, correspondant au [Single-line string pattern](#).

Nom du champ tel qu'il apparaît dans le schéma de table et dans les opérations de requête.

- **Type— Obligatoire** : une structure vide nommée. `IcebergDocument`

Définition du type de données pour ce champ, spécifiant la structure et le format des données qu'il contient.

- **Required – obligatoire** : booléen.

Indique si ce champ est obligatoire (non nullable) ou facultatif (nullable) dans le schéma de table.

- **Doc – Chaîne de commentaire**, d'une longueur maximale de 255 octets, correspondant au [Single-line string pattern](#).

Documentation facultative ou texte de description fournissant un contexte supplémentaire sur l'objectif et l'utilisation de ce champ.

IcebergTableUpdate structure

Définit un ensemble complet de mises à jour à appliquer à une table Iceberg, y compris les modifications de schéma, les modifications de partitionnement, les ajustements d'ordre de tri, les mises à jour de localisation et les modifications de propriétés.

Champs

- **Schema – Obligatoire** : un objet [IcebergSchema](#).

Définition de schéma mise à jour pour la table Iceberg, spécifiant les modifications apportées à la structure des champs, aux types de données ou aux métadonnées du schéma.

- **PartitionSpec – Un objet** [IcebergPartitionSpec](#).

Spécification de partitionnement mise à jour qui définit la manière dont les données de la table doivent être réorganisées et partitionnées.

- **SortOrder – Un objet** [IcebergSortOrder](#).

Spécification d'ordre de tri mise à jour qui définit la manière dont les données doivent être ordonnées au sein des partitions pour des performances de requête optimales.

- **Location**— Obligatoire : chaîne de localisation, d'une longueur maximale de 2 056 octets, correspondant au [URI address multi-line string pattern](#).

Emplacement S3 mis à jour où les données de la table Iceberg seront stockées.

- **Properties** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Paires clé-valeur mises à jour des propriétés de table et des paramètres de configuration de la table Iceberg.

Opérations

- [CreateTable action \(Python : créer_table\)](#)
- [UpdateTable action \(Python : update_table\)](#)
- [DeleteTable action \(Python : supprimer_table\)](#)
- [BatchDeleteTable action \(Python : batch_delete_table\)](#)
- [GetTable action \(Python : get_table\)](#)
- [GetTables action \(Python : get_tables\)](#)
- [GetTableVersion action \(Python : get_table_version\)](#)
- [GetTableVersions action \(Python : get_table_versions\)](#)
- [DeleteTableVersion action \(Python : supprimer_table_version\)](#)
- [BatchDeleteTableVersion action \(Python : batch_delete_table_version\)](#)
- [SearchTables action \(Python : tables de recherche\)](#)
- [GetPartitionIndexes action \(Python : get_partition_indexes\)](#)
- [CreatePartitionIndex action \(Python : create_partition_index\)](#)
- [DeletePartitionIndex action \(Python : delete_partition_index\)](#)
- [GetColumnStatisticsForTable action \(Python : get_column_statistics_for_table\)](#)
- [UpdateColumnStatisticsForTable action \(Python : update_column_statistics_for_table\)](#)
- [DeleteColumnStatisticsForTable action \(Python : delete_column_statistics_for_table\)](#)

CreateTable action (Python : créer_table)

Crée une nouvelle définition de table dans le catalogue de données.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel créer la Table. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Base de données du catalogue dans laquelle créer la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la table de la base de données spécifiée qui sera créée dans le catalogue de AWS Glue données.

- `TableInput` – Obligatoire : un objet [TableInput](#).

Objet `TableInput` qui définit la table de métadonnées à créer dans le catalogue.

- `PartitionIndexes` – Un tableau d'objets [PartitionIndex](#), 3 structures au maximum.

Liste d'index de partition, structures de type `PartitionIndex`, à créer dans la table.

- `TransactionId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #43](#).

ID de la transaction.

- `OpenTableFormatInput` – Un objet [OpenTableFormatInput](#).

Spécifie une structure `OpenTableFormatInput` lors de la création d'un tableau au format ouvert.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `AlreadyExistsException`
- `InvalidInputException`
- `EntityNotFoundException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ConcurrentModificationException`
- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`

UpdateTable action (Python : `update_table`)

Met à jour une table de métadonnées dans le catalogue de données.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où réside la table. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la table de la base de données spécifiée qui sera créée dans le catalogue de AWS Glue données.

- `TableInput` – Un objet [TableInput](#).

Objet TableInput mis à jour qui définit la table de métadonnées du catalogue.

- SkipArchive – Booléen.

Par défaut, UpdateTable crée toujours une version archivée de la table avant de la mettre à jour.

Toutefois, si skipArchive a la valeur true, UpdateTable ne crée pas la version archivée.

- TransactionId – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #43](#).

L'ID de transaction auquel le contenu de la table doit être mis à jour.

- VersionId – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de la version selon laquelle le contenu du tableau doit être mis à jour.

- ViewUpdateAction – Chaîne UTF-8 (valeurs valides : ADD | REPLACE | ADD_OR_REPLACE | DROP).

Opération à effectuer lors de la mise à jour de la vue.

- Force – Booléen.

Un indicateur qui peut être défini sur true pour ignorer les exigences de correspondance entre le descripteur de stockage et le sous-objet correspondants.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- EntityNotFoundException
- InvalidInputException
- InternalServiceException
- OperationTimeoutException
- ConcurrentModificationException
- ResourceNumberLimitExceededException
- GlueEncryptionException

- ResourceNotReadyException
- FederationSourceException
- FederationSourceRetryableException
- AlreadyExistsException

DeleteTable action (Python : `supprimer_table`)

Supprime une définition de table du catalogue de données.

Note

Après avoir effectué cette opération, vous n'avez plus accès aux versions et partitions de table appartenant à la table supprimée. AWS Glue supprime ces ressources « orphelines » de manière asynchrone en temps opportun, à la discrétion du service.

Pour garantir la suppression immédiate de toutes les ressources connexes, avant d'appeler `DeleteTable`, utilisez `DeleteTableVersion` ou `BatchDeleteTableVersion`, et `DeletePartition` ou `BatchDeletePartition`, pour supprimer les ressources appartenant à la table.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où réside la table. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table à supprimer. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- `TransactionId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #43](#).

L'ID de transaction pour laquelle supprimer le contenu de la table.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`
- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`

BatchDeleteTable action (Python : `batch_delete_table`)

Supprime plusieurs tables à la fois.

Note

Après avoir effectué cette opération, vous n'avez plus accès aux versions et partitions de table appartenant à la table supprimée. AWS Glue supprime ces ressources « orphelines » de manière asynchrone en temps opportun, à la discrétion du service.

Pour garantir la suppression immédiate de toutes les ressources connexes, avant d'appeler `BatchDeleteTable`, utilisez `DeleteTableVersion` ou `BatchDeleteTableVersion`, et `DeletePartition` ou `BatchDeletePartition`, pour supprimer les ressources appartenant à la table.

Demande

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où réside la table. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de catalogue où résident les tables à supprimer. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- **TablesToDelete** – Obligatoire : Tableau de chaînes UTF-8, avec 100 chaînes maximum.

Liste des tables à supprimer.

- **TransactionId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #43](#).

L'ID de transaction pour laquelle supprimer le contenu de la table.

Réponse

- **Errors** – Un tableau d'objets [TableError](#).

Liste des erreurs survenues dans la tentative de supprimer les tables spécifiées.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ResourceNotReadyException`

GetTable action (Python : get_table)

Extrait la définition de Table d'un catalogue de données pour une table spécifiée.

Demande

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où réside la table. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table pour laquelle récupérer la définition. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- **TransactionId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #43](#).

L'ID de transaction pour laquelle lire le contenu de la table.

- **QueryAsOfTime** – Horodatage.

L'Heure à laquelle lire le contenu de la table. S'il n'est pas défini, l'heure de validation de transaction la plus récente sera utilisée. Ne peut pas être spécifié avec TransactionId.

- **IncludeStatusDetails** – Booléen.

Spécifie s'il faut inclure les détails du statut relatifs à une demande de création ou de mise à jour d'une vue du catalogue de AWS Glue données.

Réponse

- **Table** – Un Objet [Tableau](#).

Objet Table qui définit la table spécifiée.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`

GetTables action (Python : `get_tables`)

Récupère les définitions de tout ou partie des tables dans une Database donnée.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID du catalogue de données où résident les tables. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Base de données du catalogue dont les tables doivent être affichées. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- `Expression` – Chaîne UTF-8, d'une longueur maximale de 2 048 octets, correspondant au [Single-line string pattern](#).

Modèle d'expression régulière. S'il est présent, seules les tables dont les noms correspondent au modèle sont renvoyées.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, inclus s'il s'agit d'un appel de continuation.

- `MaxResults` – Nombre (entier), compris entre 1 et 100.

Nombre maximal de tables à renvoyer dans une seule réponse.

- **TransactionId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #43](#).

L'ID de transaction pour laquelle lire le contenu de la table.

- **QueryAsOfTime** – Horodatage.

L'Heure à laquelle lire le contenu de la table. S'il n'est pas défini, l'heure de validation de transaction la plus récente sera utilisée. Ne peut pas être spécifié avec **TransactionId**.

- **IncludeStatusDetails** – Booléen.

Spécifie s'il faut inclure les détails du statut relatifs à une demande de création ou de mise à jour d'une vue du catalogue de AWS Glue données.

- **AttributesToGet** – Tableau de chaînes UTF-8.

Spécifie les champs de table renvoyés par l'**GetTables**appel. Ce paramètre n'accepte pas une liste vide. La demande doit inclure **NAME**.

Les combinaisons de valeurs valides sont les suivantes :

- **NAME**- Noms de toutes les tables de la base de données.
- **NAME, TABLE_TYPE** - Noms de toutes les tables et des types de tables.

Réponse

- **TableList** – Un tableau d'objets [Tableau](#).

Liste des objets **Table** demandés.

- **NextToken** – Chaîne UTF-8.

Jeton de continuation, présent si le segment de liste actuel n'est pas le dernier.

Erreurs

- **EntityNotFoundException**
- **InvalidInputException**
- **OperationTimeoutException**

- `InternalServiceException`
- `GlueEncryptionException`
- `FederationSourceException`
- `FederationSourceRetryableException`

GetTableVersion action (Python : `get_table_version`)

Extrait une version spécifiée d'une table.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID du catalogue de données où résident les tables. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Base de données du catalogue où se trouve la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- `VersionId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Valeur d'ID de la version de table à récupérer. Un `VersionID` est une représentation de chaîne d'un nombre entier. Chaque version est incrémentée par 1.

Réponse

- `TableVersion` – Un objet [TableVersion](#).

Version de table demandée.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

GetTableVersions action (Python : `get_table_versions`)

Extrait une liste de chaînes qui identifient les versions disponibles d'une table spécifiée.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID du catalogue de données où résident les tables. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Base de données du catalogue où se trouve la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il ne s'agit pas du premier appel.

- `MaxResults` – Nombre (entier), compris entre 1 et 100.

Nombre maximal de versions de table à renvoyer dans une réponse.

Réponse

- `TableVersions` – Un tableau d'objets [TableVersion](#).

Liste de chaînes qui identifient les versions disponibles de la table spécifiée.

- NextToken – Chaîne UTF-8.

Jeton de continuation, si la liste des version disponibles n'inclut pas la dernière version.

Erreurs

- EntityNotFoundException
- InvalidInputException
- InternalServiceException
- OperationTimeoutException
- GlueEncryptionException

DeleteTableVersion action (Python : supprimer_table_version)

Supprime une version spécifiée d'une table.

Demande

- CatalogId – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID du catalogue de données où résident les tables. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- DatabaseName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Base de données du catalogue où se trouve la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- TableName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- VersionId – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de la version de table à supprimer. Un `VersionID` est une représentation de chaîne d'un nombre entier. Chaque version est incrémentée par 1.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

BatchDeleteTableVersion action (Python : `batch_delete_table_version`)

Supprime un lot spécifié de versions d'une table.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID du catalogue de données où résident les tables. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Base de données du catalogue où se trouve la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table. Pour la compatibilité Hive, ce nom doit être entièrement en minuscules.

- `VersionIds` – Obligatoire : Tableau de chaînes UTF-8, avec 100 chaînes maximum.

Liste IDs des versions à supprimer. Un `VersionId` est une représentation de chaîne d'un nombre entier. Chaque version est incrémentée par 1.

Réponse

- `Errors` – Un tableau d'objets [TableVersionError](#).

Liste des erreurs survenues lors de la tentative de suppression des versions de table spécifiées.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

SearchTables action (Python : tables de recherche)

Recherche un ensemble de tables en fonction des propriétés figurant dans les métadonnées de table, ainsi que dans la base de données parent. Vous pouvez effectuer une recherche sur des conditions de texte ou de filtre.

Vous pouvez uniquement obtenir les tables auxquelles vous avez accès en fonction des stratégies de sécurité définies dans Lake Formation. Vous avez besoin d'au moins un accès en lecture seule à la table pour qu'elle soit renvoyée. Si vous n'avez pas accès à toutes les colonnes de la table, ces colonnes ne feront pas l'objet d'une recherche lorsque la liste des tables vous sera renvoyée. Si vous avez accès aux colonnes, mais pas aux données des colonnes, ces colonnes et les métadonnées associées pour ces colonnes seront incluses dans la recherche.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique, composé de *account_id*.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, inclus s'il s'agit d'un appel de continuation.

- **Filters** – Un tableau d'objets [PropertyPredicate](#).

Liste de paires clé-valeur et comparateur utilisé pour filtrer les résultats de recherche. Renvoie toutes les entités correspondant au prédicat.

Le membre **Comparator** du struct **PropertyPredicate** est utilisé uniquement pour les champs temporels et peut être omis pour d'autres types de champs. En outre, lors de la comparaison de valeurs de chaîne, par exemple lorsque **Key=Name**, un algorithme de correspondance floue (fuzzy match) est utilisé. Le champ **Key** (par exemple, la valeur du champ **Name**) est divisé en jetons sur certains caractères de ponctuation, par exemple -, :, #, etc.. Ensuite, chaque jeton est comparé de manière exacte à un membre **Value** de **PropertyPredicate**. Par exemple, si **Key=Name** et **Value=link**, les tables nommées **customer-link** et **xx-link-yy** sont retournées, mais **xxlinkyy** ne l'est pas.

- **SearchText**— Chaîne de valeurs d'une longueur d'au moins 1 ou de 1 024 octets.

Chaîne utilisée pour une recherche de texte.

La spécification d'une valeur entre guillemets filtre en fonction d'une correspondance exacte avec cette valeur.

- **SortCriteria** – Un tableau d'objets [SortCriterion](#), pas plus d'une structure.

Liste de critères de tri des résultats par un nom de champ, dans un ordre croissant ou décroissant.

- **MaxResults** – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de tables à renvoyer dans une seule réponse.

- **ResourceShareType** – Chaîne UTF-8 (valeurs valides : **FOREIGN** | **ALL** | **FEDERATED**).

Permet de spécifier que vous souhaitez rechercher les tables partagées avec votre compte. Les valeurs autorisées sont **FOREIGN** ou **ALL**.

- Si défini sur **FOREIGN**, effectuera une recherche dans les tables partagées avec votre compte.
- Si défini sur **ALL**, effectuera une recherche dans les tables partagées avec votre compte, ainsi que les tables dans votre compte local.
- **IncludeStatusDetails** – Booléen.

Spécifie s'il faut inclure les détails du statut relatifs à une demande de création ou de mise à jour d'une vue du catalogue de AWS Glue données.

Réponse

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, présent si le segment de liste actuel n'est pas le dernier.

- `TableList` – Un tableau d'objets [Tableau](#).

Liste des objets `Table` demandés. La réponse `SearchTables` renvoie uniquement les tables auxquelles vous avez accès.

Erreurs

- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

GetPartitionIndexes action (Python : `get_partition_indexes`)

Récupère les index de partition associés à une table.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue où réside la table.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Spécifie le nom d'une base de données à partir de laquelle vous souhaitez extraire des index de partition.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Spécifie le nom d'une table à partir de laquelle vous souhaitez extraire les index de partition.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, inclus s'il s'agit d'un appel de continuation.

Réponse

- `PartitionIndexDescriptorList` – Un tableau d'objets [PartitionIndexDescriptor](#).

Liste des descripteurs d'index.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, présent si le segment de liste actuel n'est pas le dernier.

Erreurs

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `EntityNotFoundException`
- `ConflictException`

CreatePartitionIndex action (Python : `create_partition_index`)

Crée un index de partition spécifié dans une table existante.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue où réside la table.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Spécifie le nom d'une base de données dans laquelle vous souhaitez créer un index de partition.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Spécifie le nom d'une table dans laquelle vous souhaitez créer un index de partition.

- `PartitionIndex` – Obligatoire : un objet [PartitionIndex](#).

Spécifie une structure `PartitionIndex` pour créer un index de partition dans une table existante.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `AlreadyExistsException`
- `InvalidInputException`
- `EntityNotFoundException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

DeletePartitionIndex action (Python : `delete_partition_index`)

Supprime un index de partition spécifié d'une table existante.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue où réside la table.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Spécifie le nom d'une base de données dont vous souhaitez supprimer un index de partition.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Spécifie le nom d'une table dont vous souhaitez supprimer un index de partition.

- `IndexName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'index de partition à supprimer.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `EntityNotFoundException`
- `ConflictException`
- `GlueEncryptionException`

GetColumnStatisticsForTable action (Python : `get_column_statistics_for_table`)

Récupère les statistiques de table des colonnes.

L'autorisation Identity and Access Management (IAM) requise pour cette opération est `GetTable`.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où résident les partitions en question. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de catalogue où résident les partitions.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table des partitions.

- `ColumnNames` – Obligatoire : Tableau de chaînes UTF-8, avec 100 chaînes maximum.

Une liste des noms de colonnes.

Réponse

- `ColumnStatisticsList` – Un tableau d'objets [ColumnStatistics](#).

Liste des `ColumnStatistics`.

- `Errors` – Un tableau d'objets [ColumnError](#).

La liste de ces `ColumnStatistics` informations n'a pas pu être récupérée.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

UpdateColumnStatisticsForTable action (Python : `update_column_statistics_for_table`)

Crée ou met à jour les statistiques de table des colonnes.

L'autorisation Identity and Access Management (IAM) requise pour cette opération est `UpdateTable`.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où résident les partitions en question. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de catalogue où résident les partitions.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table des partitions.

- `ColumnStatisticsList` – Obligatoire : Un tableau d'objets [ColumnStatistics](#), 25 structures maximum.

Liste des statistiques de la colonne.

Réponse

- `Errors` – Un tableau d'objets [ColumnStatisticsError](#).

Liste des `ColumnStatisticsErrors`.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

`DeleteColumnStatisticsForTable` action (Python : `delete_column_statistics_for_table`)

Récupère les statistiques de table des colonnes.

L'autorisation Identity and Access Management (IAM) requise pour cette opération est `DeleteTable`.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où résident les partitions en question. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de catalogue où résident les partitions.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table des partitions.

- `ColumnName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la colonne.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

API de partition

L'API de partition décrit les types de données et les opérations qui permettent de travailler avec les partitions.

Types de données

- [Structure de partition](#)
- [PartitionInput structure](#)
- [PartitionSpecWithSharedStorageDescriptor structure](#)
- [PartitionListComposingSpec structure](#)
- [PartitionSpecProxy structure](#)
- [PartitionValueList structure](#)

- [Structure d'un segment](#)
- [PartitionError structure](#)
- [BatchUpdatePartitionFailureEntry structure](#)
- [BatchUpdatePartitionRequestEntry structure](#)
- [StorageDescriptor structure](#)
- [SchemaReference structure](#)
- [SerDeInfo structure](#)
- [SkewedInfo structure](#)

Structure de partition

Représente une tranche de données d'une table.

Champs

- `Values` – Tableau de chaînes UTF-8.

Valeurs de la partition.

- `DatabaseName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue dans laquelle créer la partition.

- `TableName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table de base de données dans laquelle créer la partition.

- `CreationTime` – Horodatage.

Heure à laquelle la partition a été créée.

- `LastAccessTime` – Horodatage.

Dernière date d'accès à la partition.

- `StorageDescriptor` – Un objet [StorageDescriptor](#).

Fournit des informations sur l'emplacement physique où la partition est stockée.

- `Parameters` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Ces paires clé-valeur définissent les paramètres de partition.

- `LastAnalyzedTime` – Horodatage.

Dernière heure à laquelle les statistiques de colonne ont été calculées pour cette partition.

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la partition.

PartitionInput structure

Structure utilisée pour créer et mettre à jour une partition.

Champs

- `Values` – Tableau de chaînes UTF-8.

Valeurs de la partition. Bien que ce paramètre ne soit pas requis par le SDK, vous devez spécifier ce paramètre pour une entrée valide.

Les valeurs des clés de la nouvelle partition doivent être transmises sous la forme d'un tableau d'objets String qui doivent être classés dans le même ordre que les clés de partition qui apparaissent dans le préfixe Amazon S3. Sinon, les valeurs AWS Glue seront ajoutées aux mauvaises clés.

- `LastAccessTime` – Horodatage.

Dernière date d'accès à la partition.

- `StorageDescriptor` – Un objet [StorageDescriptor](#).

Fournit des informations sur l'emplacement physique où la partition est stockée.

- `Parameters` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Ces paires clé-valeur définissent les paramètres de partition.

- `LastAnalyzedTime` – Horodatage.

Dernière heure à laquelle les statistiques de colonne ont été calculées pour cette partition.

PartitionSpecWithSharedStorageDescriptor structure

Spécification de partition pour les partitions qui partagent un emplacement physique.

Champs

- `StorageDescriptor` – Un objet [StorageDescriptor](#).

Informations sur le partage du stockage physique.

- `Partitions` – Un tableau d'objets [Partition](#).

Liste des partitions qui partagent cet emplacement physique.

PartitionListComposingSpec structure

Répertorie les partitions connexes.

Champs

- `Partitions` – Un tableau d'objets [Partition](#).

Liste des partitions dans la spécification de composition.

PartitionSpecProxy structure

Fournit un chemin d'accès racine aux partitions spécifiées.

Champs

- `DatabaseName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Base de données du catalogue dans laquelle résident les partitions.

- `TableName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table contenant les partitions.

- `RootPath` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chemin d'accès racine du proxy pour l'adressage des partitions.

- `PartitionSpecWithSharedSD` – Un objet [PartitionSpecWithSharedStorageDescriptor](#).

Spécification des partitions qui partagent le même emplacement de stockage physique.

- `PartitionListComposingSpec` – Un objet [PartitionListComposingSpec](#).

Spécifie une liste de partitions.

PartitionValueList structure

Contient une liste de valeurs définissant les partitions.

Champs

- `Values` – Obligatoire : Tableau de chaînes UTF-8.

Liste de valeurs.

Structure d'un segment

Définit une région sans chevauchement des partitions d'une table, ce qui permet l'exécution en parallèle de plusieurs requêtes.

Champs

- `SegmentNumber` – Obligatoire : Nombre (entier), pas plus qu'Aucun.

Numéro d'index de base zéro du segment. Par exemple, si le nombre total de segments est 4, les valeurs `SegmentNumber` vont de 0 à 3.

- `TotalSegments` – Obligatoire : Nombre (entier), compris entre 1 et 10.

Nombre total de segments.

PartitionError structure

Contient les informations sur une erreur de partition.

Champs

- `PartitionValues` – Tableau de chaînes UTF-8.

Valeurs qui définissent la partition.

- `ErrorDetail` – Un objet [ErrorDetail](#).

Détails sur l'erreur de partition.

BatchUpdatePartitionFailureEntry structure

Contient des informations sur une erreur de partition de mise à jour par lots.

Champs

- `PartitionValueList` – Tableau de chaînes UTF-8, avec 100 chaînes maximum.

Liste des valeurs définissant la partition.

- `ErrorDetail` – Un objet [ErrorDetail](#).

Détails sur l'erreur de partition de mise à jour par lots.

BatchUpdatePartitionRequestEntry structure

Structure contenant les valeurs et la structure utilisées pour mettre à jour une partition.

Champs

- `PartitionValueList` – Obligatoire : Tableau de chaînes UTF-8, avec 100 chaînes maximum.

Liste des valeurs définissant la partition.

- `PartitionInput` – Obligatoire : un objet [PartitionInput](#).

Structure utilisée pour mettre à jour une partition.

StorageDescriptor structure

Décrit le stockage physique des données de table.

Champs

- `Columns` – Un tableau d'objets [Colonne](#).

Liste des `Columns` de la table.

- `Location` – Chaîne de localisation, d'une longueur maximale de 2 056 octets, correspondant au [URI address multi-line string pattern](#).

Emplacement physique de la table. Par défaut, il prend la forme de l'emplacement de entrepôt, suivie de l'emplacement de la base de données dans l'entrepôt, suivi du nom de la table.

- `AdditionalLocations` – Tableau de chaînes UTF-8.

Liste des emplacements pointant vers le chemin d'accès où se trouve une table Delta.

- `InputFormat` – Chaîne de format, d'une longueur maximale de 128 octets, correspondant au [Single-line string pattern](#).

Format d'entrée : `SequenceFileInputFormat` (binaire) ou `TextInputFormat` ou format personnalisé.

- `OutputFormat` – Chaîne de format, d'une longueur maximale de 128 octets, correspondant au [Single-line string pattern](#).

Format de sortie : `SequenceFileOutputFormat` (binaire) ou `IgnoreKeyTextOutputFormat` ou format personnalisé.

- `Compressed` – Booléen.

`True` si les données de la table sont compressées ou `False` si elles ne le sont pas.

- `NumberOfBuckets` – Nombre (entier).

Doit être spécifié si la table contient des colonnes de dimension.

- `SerdeInfo` – Un objet [SerDeInfo](#).

Les informations de sérialisation/désérialisation (). `SerDe`

- `BucketColumns` – Tableau de chaînes UTF-8.

Liste de colonnes de regroupement de réducteur, de colonnes de clustérisation et de colonnes de mise en compartiment de la table.

- `SortColumns` – Un tableau d'objets [Ordre](#).

Liste spécifiant l'ordre de tri de chaque compartiment de la table.

- `Parameters` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Propriétés fournies par l'utilisateur sous la forme clé-valeur.

- `SkewedInfo` – Un objet [SkewedInfo](#).

Informations concernant les valeurs qui apparaissent fréquemment dans une colonne (valeurs asymétriques).

- `StoredAsSubDirectories` – Booléen.

`True` si les données de la table sont stockées dans les sous-répertoires ou `False` dans le cas contraire.

- `SchemaReference` – Un objet [SchemaReference](#).

Objet qui fait référence à un schéma stocké dans le registre des AWS Glue schémas.

Lors de la création d'une table, vous pouvez transmettre une liste vide de colonnes pour le schéma et plutôt utiliser une référence de schéma.

SchemaReference structure

Objet qui fait référence à un schéma stocké dans le registre des AWS Glue schémas.

Champs

- `SchemaId` – Un objet [Schemald](#).

Structure qui contient des champs d'identité de schéma. Ceci ou `SchemaVersionId` doit être fourni.

- `SchemaVersionId` – Obligatoire : chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

ID unique affecté à une version du schéma. Ceci ou `SchemaId` doit être fourni.

- `SchemaVersionNumber` – Nombre (long), compris entre 1 et 100 000.

Numéro de version du schéma.

SerdeInfo structure

Informations sur un programme de sérialisation/désérialisation (SerDe) qui sert d'extracteur et de chargeur.

Champs

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du SerDe.

- `SerializationLibrary` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Généralement, la classe qui implémente le SerDe. Par exemple :
`org.apache.hadoop.hive.serde2.columnar.ColumnarSerDe`.

- `Parameters` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne de clé, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 512 000 octets.

Ces paires clé-valeur définissent les paramètres d'initialisation pour. SerDe

SkewedInfo structure

Spécifie les valeurs biaisées d'une table. Les valeurs biaisées sont celles qui se produisent à très haute fréquence.

Champs

- `SkewedColumnNames` – Tableau de chaînes UTF-8.

Liste des noms de colonnes qui contiennent des valeurs biaisées.

- `SkewedColumnValues` – Tableau de chaînes UTF-8.

Liste des valeurs qui apparaissent si fréquemment qu'elles sont considérées comme biaisées.

- `SkewedColumnValueLocationMaps` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Mappage de valeurs biaisées avec les colonnes qui les contiennent.

Opérations

- [CreatePartition action \(Python : créer_partition\)](#)
- [BatchCreatePartition action \(Python : batch_create_partition\)](#)
- [UpdatePartition action \(Python : update_partition\)](#)
- [DeletePartition action \(Python : supprimer_partition\)](#)
- [BatchDeletePartition action \(Python : batch_supprimer_partition\)](#)
- [GetPartition action \(Python : get_partition\)](#)
- [GetPartitions action \(Python : get_partitions\)](#)
- [BatchGetPartition action \(Python : batch_get_partition\)](#)
- [BatchUpdatePartition action \(Python : batch_update_partition\)](#)
- [GetColumnStatisticsForPartition action \(Python : get_column_statistics_for_partition\)](#)
- [UpdateColumnStatisticsForPartition action \(Python : update_column_statistics_for_partition\)](#)
- [DeleteColumnStatisticsForPartition action \(Python : supprimer_column_statistics_for_partition\)](#)

CreatePartition action (Python : créer_partition)

Crée une partition.

Demande

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de AWS compte du catalogue dans lequel la partition doit être créée.

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de métadonnées dans laquelle la partition doit être créée.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table de métadonnées dans laquelle la partition doit être créée.

- **PartitionInput** – Obligatoire : un objet [PartitionInput](#).

Structure `PartitionInput` définissant la partition à créer.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `InvalidInputException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `GlueEncryptionException`

BatchCreatePartition action (Python : batch_create_partition)

Crée une ou plusieurs partitions dans une opération par lot.

Demande

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue dans lequel la partition doit être créée. Actuellement, il devrait s'agir de l'identifiant du AWS compte.

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de métadonnées dans laquelle la partition doit être créée.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table de métadonnées dans laquelle la partition doit être créée.

- **PartitionInputList** – Obligatoire : Un tableau d'objets [PartitionInput](#), 100 structures maximum.

Liste de structures `PartitionInput` qui définissent les partitions à créer.

Réponse

- **Errors** – Un tableau d'objets [PartitionError](#).

Erreurs survenues pendant la tentative de création des partitions demandées.

Erreurs

- `InvalidInputException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`

- `GlueEncryptionException`

UpdatePartition action (Python : `update_partition`)

Met à jour une partition.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où réside la partition à mettre à jour. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table en question.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table où se trouve la partition à mettre à jour.

- `PartitionValueList` – Obligatoire : Tableau de chaînes UTF-8, avec 100 chaînes maximum.

Liste des valeurs de clé de partition qui définissent la partition à mettre à jour.

- `PartitionInput` – Obligatoire : un objet [PartitionInput](#).

Nouvel objet de partition où mettre à jour la partition.

Cette propriété `Values` ne peut pas être modifiée. Si vous souhaitez modifier les valeurs de clé de partition d'une partition, supprimez et recréez la partition.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

DeletePartition action (Python : `supprimer_partition`)

Supprime une partition spécifiée.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où réside la partition à supprimer. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table en question.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table qui contient la partition à supprimer.

- `PartitionValues` – Obligatoire : Tableau de chaînes UTF-8.

Valeurs qui définissent la partition.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`

- `OperationTimeoutException`

BatchDeletePartition action (Python : `batch_supprimer_partition`)

Supprime une ou plusieurs partitions dans une opération par lot.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où réside la partition à supprimer. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table en question.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table contenant les partitions à supprimer.

- `PartitionsToDelete` – Obligatoire : Un tableau d'objets [PartitionValueList](#), 25 structures maximum.

Liste de structures `PartitionInput` qui définissent les partitions à supprimer.

Réponse

- `Errors` – Un tableau d'objets [PartitionError](#).

Erreurs survenues pendant la tentative de suppression des partitions demandées.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

GetPartition action (Python : get_partition)

Extrait les informations sur une partition spécifiée.

Demande

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où réside la partition en question. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de catalogue où réside la partition.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table des partitions.

- **PartitionValues** – Obligatoire : Tableau de chaînes UTF-8.

Valeurs qui définissent la partition.

Réponse

- **Partition** – Un objet [Partition](#).

Informations demandées, sous la forme d'un objet `Partition`.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `FederationSourceException`

- `FederationSourceRetryableException`

GetPartitions action (Python : `get_partitions`)

Extrait les informations sur les partitions d'une table.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où résident les partitions en question. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de catalogue où résident les partitions.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table des partitions.

- `Expression` – Chaîne de prédicat, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Expression qui filtre les partitions à renvoyer.

L'expression utilise une syntaxe SQL similaire à la clause de filtre WHERE SQL. L'analyseur d'instructions SQL [JSQLParser](#) analyse l'expression.

Opérateurs : voici les opérateurs que vous pouvez utiliser dans l'appel d'API `Expression` :

=

Vérifie si les valeurs des deux opérandes sont égales ; si c'est le cas, la condition est vraie.

Exemple : supposons que la « variable a » et la « variable b » sont de 20.

(a = b) n'est pas vrai.

< >

Vérifie si les valeurs des deux opérandes sont égales ; si ce n'est pas le cas, la condition est vraie.

Exemple : (a < > b) est vrai.

>

Vérifie si la valeur de l'opérande gauche est supérieure à la valeur de l'opérande droite ; si c'est le cas, la condition est vraie.

Exemple : (a > b) n'est pas vrai.

<

Vérifie si la valeur de l'opérande gauche est inférieure à la valeur de l'opérande droite ; si c'est le cas, la condition est vraie.

Exemple : (a < b) est vrai.

>=

Vérifie si la valeur de l'opérande gauche est supérieure ou égale à la valeur de l'opérande droite ; si c'est le cas, la condition est vraie.

Exemple : (a >= b) n'est pas vrai.

<=

Vérifie si la valeur de l'opérande gauche est inférieure ou égale à la valeur de l'opérande droite ; si c'est le cas, la condition est vraie.

Exemple : (a <= b) est vrai.

AND, OR, IN, BETWEEN, LIKE, NOT, IS NULL

Opérateurs logiques.

Types de clés de partition prises en charge : les clés de partition prises en charge sont énoncées ci-dessous.

- string
- date

- `int`
- `bigint`
- `long`
- `tinyint`
- `smallint`
- `decimal`

Si un type non valide est rencontré, une exception est levée.

La liste suivante présente les opérateurs valides sur chaque type. Lorsque vous définissez un crawler, le type `partitionKey` est créé en tant que `STRING`, pour être compatible avec le catalogue de partitions.

Exemple d'appel d'API :

Exemple

La table `twitter_partition` comprend trois partitions :

```
year = 2015
    year = 2016
    year = 2017
```

Exemple

Obtenir la partition `year` équivalant à 2015

```
aws glue get-partitions --database-name dbname --table-name twitter_partition
    --expression "year*='2015'"
```

Exemple

Obtenir la partition `year` entre 2016 et 2018 (exclusif)

```
aws glue get-partitions --database-name dbname --table-name twitter_partition
    --expression "year>'2016' AND year<'2018'"
```

Exemple

Obtenir la partition `year` entre 2015 et 2018 (inclusif). Les appels d'API suivants sont équivalents :

```
aws glue get-partitions --database-name dbname --table-name twitter_partition
    --expression "year>='2015' AND year<='2018'"

aws glue get-partitions --database-name dbname --table-name
twitter_partition
    --expression "year BETWEEN 2015 AND 2018"

aws glue get-partitions --database-name dbname --table-name
twitter_partition
    --expression "year IN (2015,2016,2017,2018)"
```

Exemple

Une partition à caractère générique où la sortie d'appel suivante est la partition année = 2017. Une expression régulière n'est pas prise en charge dans `LIKE`.

```
aws glue get-partitions --database-name dbname --table-name twitter_partition
    --expression "year LIKE '%7'"
```

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, si ce n'est pas le premier appel pour récupérer ces partitions.

- `Segment` – Un objet [Segment](#).

Segment des partitions de la table à analyser dans cette demande.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de partitions à renvoyer dans une seule réponse.

- `ExcludeColumnSchema` – Booléen.

Lorsque la valeur est « `true` (VRAI) », indique de ne pas renvoyer le schéma de la colonne de partition. Utile lorsque vous êtes intéressé uniquement par d'autres attributs de partition tels que les valeurs de partition ou l'emplacement. En ne renvoyant pas de données en double, cette approche évite le problème d'une grande réponse.

- `TransactionId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #43](#).

L'ID de transaction auquel lire le contenu de la partition.

- `QueryAsOfTime` – Horodatage.

L'Heure à laquelle lire le contenu de la partition. S'il n'est pas défini, l'heure de validation de transaction la plus récente sera utilisée. Ne peut pas être spécifié avec `TransactionId`.

Réponse

- `Partitions` – Un tableau d'objets [Partition](#).

Liste des partitions demandées.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, si la liste de partitions renvoyée n'inclut pas la dernière partition.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`
- `InvalidStateException`
- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`

BatchGetPartition action (Python : `batch_get_partition`)

Extrait les partitions d'une demande par lot.

Demande

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où résident les partitions en question. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de catalogue où résident les partitions.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table des partitions.

- **PartitionsToGet** – Obligatoire : Un tableau d'objets [PartitionValueList](#), 1000 structures maximum.

Liste des valeurs de partition qui identifie les partitions à récupérer.

Réponse

- **Partitions** – Un tableau d'objets [Partition](#).

Liste des partitions demandées.

- **UnprocessedKeys** – Un tableau d'objets [PartitionValueList](#), 1000 structures maximum.

Liste des valeurs de partition de la demande pour laquelle les partitions n'ont pas été retournées.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`
- `InvalidStateException`

- `FederationSourceException`
- `FederationSourceRetryableException`

BatchUpdatePartition action (Python : `batch_update_partition`)

Met à jour une ou plusieurs partitions dans une opération par lot.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue dans lequel la partition doit être mise à jour. Actuellement, il devrait s'agir de l'identifiant du AWS compte.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de métadonnées dans laquelle la partition doit être mise à jour.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table de métadonnées dans laquelle la partition doit être mise à jour.

- `Entries` – Obligatoire : Tableau d'objets [BatchUpdatePartitionRequestEntry](#), 1 structure minimum et 100 structures maximum.

Une liste de jusqu'à 100 objets `BatchUpdatePartitionRequestEntry` à mettre à jour.

Réponse

- `Errors` – Un tableau d'objets [BatchUpdatePartitionFailureEntry](#).

Erreurs survenues pendant la tentative de mise à jour des partitions demandées. Liste d'objets `BatchUpdatePartitionFailureEntry`.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`

- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`

GetColumnStatisticsForPartition action (Python : `get_column_statistics_for_partition`)

Récupère les statistiques de partition des colonnes.

L'autorisation Identity and Access Management (IAM) requise pour cette opération est `GetPartition`.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où résident les partitions en question. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de catalogue où résident les partitions.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table des partitions.

- `PartitionValues` – Obligatoire : Tableau de chaînes UTF-8.

Liste des valeurs de partition qui identifie la partition.

- `ColumnNames` – Obligatoire : Tableau de chaînes UTF-8, avec 100 chaînes maximum.

Une liste des noms de colonnes.

Réponse

- `ColumnStatisticsList` – Un tableau d'objets [ColumnStatistics](#).

La liste n' `ColumnStatistics` a pas pu être récupérée.

- **Errors** – Un tableau d'objets [ColumnError](#).

Une erreur s'est produite lors de la récupération des données statistiques de colonne.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

`UpdateColumnStatisticsForPartition` action (Python : `update_column_statistics_for_partition`)

Crée ou met à jour les statistiques de partition des colonnes.

L'autorisation Identity and Access Management (IAM) requise pour cette opération est `UpdatePartition`.

Demande

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où résident les partitions en question. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de catalogue où résident les partitions.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table des partitions.

- **PartitionValues** – Obligatoire : Tableau de chaînes UTF-8.

Liste des valeurs de partition qui identifie la partition.

- `ColumnStatisticsList` – Obligatoire : Un tableau d'objets [ColumnStatistics](#), 25 structures maximum.

Liste des statistiques de la colonne.

Réponse

- `Errors` – Un tableau d'objets [ColumnStatisticsError](#).

Une erreur s'est produite lors de la mise à jour des données statistiques.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

`DeleteColumnStatisticsForPartition` action (Python : `supprimer_column_statistics_for_partition`)

Supprime les statistiques de colonne de partition d'une colonne.

L'autorisation Identity and Access Management (IAM) requise pour cette opération est `DeletePartition`.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où résident les partitions en question. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données de catalogue où résident les partitions.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table des partitions.

- **PartitionValues** – Obligatoire : Tableau de chaînes UTF-8.

Liste des valeurs de partition qui identifie la partition.

- **ColumnName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la colonne.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

API de connexions

L'API Connections décrit les types de données et l'API liés à l'utilisation des connexions dans AWS Glue.

Rubriques

- [API de connexion](#)
- [API des types de connexion](#)
- [Métadonnées de connexion et API de prévisualisation](#)

API de connexion

L'API de AWS Glue connexion décrit les types de données de connexion et l'API permettant de créer, de supprimer, de mettre à jour et de répertorier les connexions.

Types de données

- [Structure de connexion](#)
- [ConnectionInput structure](#)
- [TestConnectionInput structure](#)
- [PhysicalConnectionRequirements structure](#)
- [GetConnectionsFilter structure](#)
- [AuthenticationConfiguration structure](#)
- [AuthenticationConfigurationInput structure](#)
- [OAuth2Structure des propriétés](#)
- [OAuth2PropertiesInput structure](#)
- [OAuth2ClientApplication structure](#)
- [AuthorizationCodeProperties structure](#)
- [BasicAuthenticationCredentials structure](#)
- [OAuth2Structure des informations d'identification](#)

Structure de connexion

Définit une connexion à une source de données.

Champs

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de connexion.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la connexion.

- **ConnectionType**— Chaîne UTF-8 (valeurs valides : JDBC | SFTP | MONGODB | KAFKA | NETWORK | MARKETPLACE | CUSTOM | SALESFORCE | VIEW_VALIDATION_REDSHIFT | VIEW_VALIDATION_ATHENA | GOOGLEADS | GOOGLESHEETS | GOOGLEANALYTICS4 | SERVICENOW | MARKETO | SAPODATA | ZENDESK | JIRACLOUD | NETSUITEERP | HUBSPOT | FACEBOOKADS | INSTAGRAMADS | ZOHOCRM | SALESFORCEPARDOT | SALESFORCEMARKETINGCLOUD | SLACK STRIPE INTERCOM | SNAPCHATADS).

Type de connexion. Actuellement, SFTP n'est pas pris en charge.

- **MatchCriteria** – Tableau de chaînes UTF-8, avec 10 chaînes maximum.

Liste des critères qui peuvent être utilisés dans la sélection de cette connexion.

- **ConnectionProperties** – Tableau de mappage de paires clé-valeur, 100 paires au maximum.

Chaque clé est une chaîne UTF-8 (valeurs valides : HOST | PORT | USERNAME="USER_NAME" | PASSWORD | ENCRYPTED_PASSWORD | JDBC_DRIVER_JAR_URI | JDBC_DRIVER_CLASS_NAME | JDBC_ENGINE | JDBC_ENGINE_VERSION | CONFIG_FILES | INSTANCE_ID | JDBC_CONNECTION_URL | JDBC_ENFORCE_SSL | CUSTOM_JDBC_CERT | SKIP_CUSTOM_JDBC_CERT_VALIDATION | CUSTOM_JDBC_CERT_STRING | CONNECTION_URL | KAFKA_BOOTSTRAP_SERVERS | KAFKA_SSL_ENABLED | KAFKA_CUSTOM_CERT | KAFKA_SKIP_CUSTOM_CERT_VALIDATION | KAFKA_CLIENT_KEYSTORE | KAFKA_CLIENT_KEYSTORE_PASSWORD | KAFKA_CLIENT_KEY_PASSWORD | ENCRYPTED_KAFKA_CLIENT_KEYSTORE_PASSWORD | ENCRYPTED_KAFKA_CLIENT_KEY_PASSWORD | KAFKA_SASL_MECHANISM | KAFKA_SASL_PLAIN_USERNAME | KAFKA_SASL_PLAIN_PASSWORD | ENCRYPTED_KAFKA_SASL_PLAIN_PASSWORD | KAFKA_SASL_SCRAM_USERNAME | KAFKA_SASL_SCRAM_PASSWORD | KAFKA_SASL_SCRAM_SECRETS_ARN | ENCRYPTED_KAFKA_SASL_SCRAM_PASSWORD | KAFKA_SASL_GSSAPI_KEYTAB | KAFKA_SASL_GSSAPI_KRB5_CONF | KAFKA_SASL_GSSAPI_SERVICE | KAFKA_SASL_GSSAPI_PRINCIPAL | SECRET_ID | CONNECTOR_URL | CONNECTOR_TYPE | CONNECTOR_CLASS_NAME | ENDPOINT | ENDPOINT_TYPE | ROLE_ARN | REGION | WORKGROUP_NAME | CLUSTER_IDENTIFIER | DATABASE).

Chaque valeur est une chaîne de valeurs d'une longueur d'au moins 1 octet ou supérieure à 1 024 octets.

Ces paires clé-valeur définissent les paramètres de la connexion lors de l'utilisation du schéma de connexion de la version 1 :

- **HOST**- L'URI de l'hôte : soit le nom de domaine complet (FQDN), soit l' IPv4 adresse de l'hôte de la base de données.
- **PORT** - Numéro du port, compris entre 1 024 et 65 535, sur lequel l'hôte de base de données écoute les connexions de la base de données.
- **USER_NAME** - Nom sous lequel vous vous connectez à la base de données. La valeur de chaîne pour **USER_NAME** est « USERNAME ».
- **PASSWORD** - Mot de passe, le cas échéant, pour le nom d'utilisateur.
- **ENCRYPTED_PASSWORD** - Lorsque vous activez la protection de mot de passe en réglant `ConnectionPasswordEncryption` dans les paramètres de chiffrement de Catalogue de données, ce champ stocke le mot de passe chiffré.
- **JDBC_DRIVER_JAR_URI** - Chemin d'accès Amazon Simple Storage Service (Amazon S3) du fichier JAR qui contient le pilote JDBC à utiliser.
- **JDBC_DRIVER_CLASS_NAME** - Nom de classe du pilote JDBC à utiliser.
- **JDBC_ENGINE** – Nom du moteur JDBC à utiliser.
- **JDBC_ENGINE_VERSION** - Version du moteur JDBC à utiliser.
- **CONFIG_FILES** - (Réservé pour une utilisation ultérieure.)
- **INSTANCE_ID** - ID d'instance à utiliser.
- **JDBC_CONNECTION_URL** - URL de connexion à une source de données JDBC.
- **JDBC_ENFORCE_SSL**- Une chaîne booléenne ne distinguant pas les majuscules et minuscules (true, false) indiquant si le protocole SSL (Secure Sockets Layer) avec correspondance de nom d'hôte est appliqué pour la connexion JDBC sur le client. La valeur par défaut est false.
- **CUSTOM_JDBC_CERT**- Un emplacement Amazon S3 spécifiant le certificat racine du client. AWS Glue utilise ce certificat racine pour valider le certificat du client lors de la connexion à la base de données clients. AWS Glue gère uniquement les certificats X.509. Le certificat fourni doit être codé DER et fourni au format PEM d'encodage Base64.
- **SKIP_CUSTOM_JDBC_CERT_VALIDATION**- Par défaut, c'est le cas `false`. AWS Glue valide l'algorithme de signature et l'algorithme de clé publique du sujet pour le certificat client. Les seuls algorithmes autorisés pour l'algorithme de signature sont SHA256with RSA, RSA ou SHA384with SHA512with RSA. Pour l'algorithme de clé publique d'objet, la longueur de clé doit être d'au moins 2048. Vous pouvez mettre la valeur de cette propriété à `true` pour ignorer la validation par AWS Glue du certificat du client.
- **CUSTOM_JDBC_CERT_STRING**- Une chaîne de certificat JDBC personnalisée qui est utilisée pour la correspondance de domaine ou de nom distinctif afin de prévenir une man-in-the-middle

attaque. Dans Oracle Database, elle est utilisée comme SSL_SERVER_CERT_DN. Dans Microsoft SQL Server, elle est utilisée comme hostNameInCertificate.

- CONNECTION_URL - URL de connexion à une source de données générale (non JDBC).
- SECRET_ID - L'ID secret utilisé pour le gestionnaire secret des informations d'identification.
- CONNECTOR_URL - L'URL du connecteur pour une connexion MARKETPLACE ou CUSTOM.
- CONNECTOR_TYPE - Le type du connecteur pour une connexion MARKETPLACE ou CUSTOM.
- CONNECTOR_CLASS_NAME - Le nom de la classe de connecteur pour une connexion MARKETPLACE ou CUSTOM.
- KAFKA_BOOTSTRAP_SERVERS - Liste séparée par des virgules composée de paires hôte et port qui sont les adresses des courtiers Apache Kafka dans un cluster Kafka auquel un client Kafka se connecte pour démarrer lui-même.
- KAFKA_SSL_ENABLED - Indique s'il convient d'activer ou de désactiver SSL sur une connexion Apache Kafka. La valeur par défaut est « true » (vrai).
- KAFKA_CUSTOM_CERT - L'URL d'Amazon S3 pour le fichier de certificat de l'autorité de certification privée (format .pem). La valeur par défaut est une chaîne vide.
- KAFKA_SKIP_CUSTOM_CERT_VALIDATION - S'il faut ou non ignorer la validation du fichier de certification CA. AWS Glue valide pour trois algorithmes : SHA256with RSA, RSA et SHA384with RSA. SHA512with La valeur par défaut est « false » (faux).
- KAFKA_CLIENT_KEYSTORE - Emplacement Amazon S3 du fichier de magasin de clés client pour l'authentification côté client Kafka (facultatif).
- KAFKA_CLIENT_KEYSTORE_PASSWORD - Le mot de passe pour accéder au magasin de clés fourni (facultatif).
- KAFKA_CLIENT_KEY_PASSWORD - Un magasin de clés peut être composé de plusieurs clés, il s'agit donc du mot de passe pour accéder à la clé client à utiliser avec la clé côté serveur Kafka (facultatif).
- ENCRYPTED_KAFKA_CLIENT_KEYSTORE_PASSWORD - La version cryptée du mot de passe du keystore du client Kafka (si l'utilisateur a sélectionné le paramètre de AWS Glue chiffrement des mots de passe).
- ENCRYPTED_KAFKA_CLIENT_KEY_PASSWORD - La version cryptée du mot de passe clé du client Kafka (si l'utilisateur a sélectionné le paramètre de AWS Glue cryptage des mots de passe).
- KAFKA_SASL_MECHANISM - "SCRAM-SHA-512", "GSSAPI", "AWS_MSK_IAM", ou "PLAIN". Ce sont les [mécanismes SASL](#) pris en charge.

- `KAFKA_SASL_PLAIN_USERNAME`- Un nom d'utilisateur en texte clair utilisé pour s'authentifier avec le mécanisme « PLAIN ».
- `KAFKA_SASL_PLAIN_PASSWORD`- Un mot de passe en texte clair utilisé pour s'authentifier avec le mécanisme « PLAIN ».
- `ENCRYPTED_KAFKA_SASL_PLAIN_PASSWORD`- La version cryptée du mot de passe Kafka SASL PLAIN (si l'utilisateur a sélectionné le paramètre de AWS Glue cryptage des mots de passe).
- `KAFKA_SASL_SCRAM_USERNAME` - Un nom d'utilisateur en texte clair utilisé pour s'authentifier avec le mécanisme « SCRAM-SHA-512 ».
- `KAFKA_SASL_SCRAM_PASSWORD` - Un mot de passe en texte clair utilisé pour s'authentifier avec le mécanisme « SCRAM-SHA-512 ».
- `ENCRYPTED_KAFKA_SASL_SCRAM_PASSWORD`- La version cryptée du mot de passe Kafka SASL SCRAM (si l'utilisateur a sélectionné le paramètre de AWS Glue cryptage des mots de passe).
- `KAFKA_SASL_SCRAM_SECRETS_ARN`- Le nom de ressource Amazon d'un secret dans AWS Secrets Manager.
- `KAFKA_SASL_GSSAPI_KEYTAB` - Emplacement S3 d'un fichier Kerberos keytab. Un keytab stocke les clés à long terme pour un ou plusieurs principaux. Pour en savoir plus, consultez [Documentation du MIT Kerberos : Keytab](#).
- `KAFKA_SASL_GSSAPI_KRB5_CONF` - Emplacement S3 d'un fichier Kerberos `krb5.conf`. Un fichier `krb5.conf` stocke les informations de configuration Kerberos, telles que l'emplacement du serveur KDC. Pour en savoir plus, consultez [Documentation MIT Kerberos : krb5.conf](#).
- `KAFKA_SASL_GSSAPI_SERVICE` - Le nom du service Kerberos, tel que défini avec `sasl.kerberos.service.name` dans votre [Configuration Kafka](#).
- `KAFKA_SASL_GSSAPI_PRINCIPAL`- Le nom du principal Kerberos utilisé par. AWS Glue Pour plus d'informations, consultez [Documentation Kafka : configuration des courtiers Kafka](#).
- `ROLE_ARN`- Le rôle à utiliser pour exécuter des requêtes.
- `REGION`- La AWS région dans laquelle les requêtes seront exécutées.
- `WORKGROUP_NAME`- Le nom d'un groupe de travail sans serveur Amazon Redshift ou d'un groupe de travail Amazon Athena dans lequel les requêtes seront exécutées.
- `CLUSTER_IDENTIFIER`- L'identifiant du cluster Amazon Redshift dans lequel les requêtes seront exécutées.
- `DATABASE`- La base de données Amazon Redshift à laquelle vous vous connectez.

- **SparkProperties** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 2 048 octets.

Propriétés de connexion spécifiques à l'environnement informatique Spark.

- **AthenaProperties** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 2 048 octets.

Propriétés de connexion spécifiques à l'environnement informatique Athena.

- **PythonProperties** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 2 048 octets.

Propriétés de connexion spécifiques à l'environnement de calcul Python.

- **PhysicalConnectionRequirements** – Un objet [PhysicalConnectionRequirements](#).

Les exigences de connexion physique, telles que le cloud privé virtuel (VPC) et `SecurityGroup`, qui sont nécessaires pour établir cette connexion avec succès.

- **CreationTime** – Horodatage.

Horodatage de l'heure à laquelle cette définition de connexion a été créée.

- **LastUpdatedTime** – Horodatage.

Horodatage de la dernière mise à jour de la définition de connexion.

- **LastUpdatedBy** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'utilisateur, groupe ou rôle qui a mis à jour la définition de connexion pour la dernière fois.

- **Status** – Chaîne UTF-8 (valeurs valides : `READY` | `IN_PROGRESS` | `FAILED`).

État de la connexion. Peut avoir l'une des valeurs suivantes : `READY`, `IN_PROGRESS` ou `FAILED`.

- **StatusReason** – Chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 16 384 octets.

Raison de l'état de la connexion.

- `LastConnectionValidationTime` – Horodatage.

Horodatage de la dernière validation de cette connexion.

- `AuthenticationConfiguration` – Un objet [AuthenticationConfiguration](#).

Les propriétés d'authentification de la connexion.

- `ConnectionSchemaVersion`— Nombre (entier), pas moins de 1 ou plus de 2.

Version du schéma de connexion pour cette connexion. La version 2 prend en charge les propriétés pour des environnements informatiques spécifiques.

- `CompatibleComputeEnvironments` – Tableau de chaînes UTF-8.

Liste des environnements informatiques compatibles avec la connexion.

ConnectionInput structure

Une structure utilisée pour spécifier la connexion à créer ou à mettre à jour.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la connexion.

- `Description` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la connexion.

- `ConnectionType`— Obligatoire : chaîne UTF-8 (valeurs valides : `JDBC` | `SFTP` | `MONGODB` | `KAFKA` | `NETWORK` | `MARKETPLACE` | `CUSTOM` | `SALESFORCE` | `VIEW_VALIDATION_REDSHIFT` | `VIEW_VALIDATION_ATHENA` | `GOOGLEADS` | `GOOGLESHEETS` | `GOOGLEANALYTICS4` | `SERVICENOW` | `MARKETO` | `SAPODATA` | `ZENDESK` | `JIRACLOUD` | `NETSUITEERP` | `HUBSPOT` | `FACEBOOKADS` | `INSTAGRAMADS` | `ZOHOCRM` | `SALESFORCEPARDOT` | `SALESFORCEMARKETINGCLOUD` | `SLACK` | `STRIPE` | `INTERCOM` | `SNAPCHATADS`).

Type de connexion. Actuellement, ces types sont pris en charge :

- `JDBC` - Désigne une connexion à une base de données via Java Database Connectivity (JDBC).

JDBC Les connexions utilisent les méthodes suivantes ConnectionParameters.

- Obligatoire : toutes les valeurs (HOST, PORT, JDBC_ENGINE) ou JDBC_CONNECTION_URL.
- Obligatoire : toutes les valeurs (USERNAME, PASSWORD) ou SECRET_ID.
- Facultatif : JDBC_ENFORCE_SSL, CUSTOM_JDBC_CERT, CUSTOM_JDBC_CERT_STRING, SKIP_CUSTOM_JDBC_CERT_VALIDATION. Ces paramètres sont utilisés pour configurer le SSL avec JDBC.
- KAFKA - Désigne une connexion à une plateforme de streaming Apache Kafka.

KAFKA Les connexions utilisent les méthodes suivantes ConnectionParameters.

- Obligatoire : KAFKA_BOOTSTRAP_SERVERS.
- Facultatif : KAFKA_SSL_ENABLED, KAFKA_CUSTOM_CERT, KAFKA_SKIP_CUSTOM_CERT_VALIDATION. Ces paramètres sont utilisés pour configurer le SSL avec KAFKA.
- Facultatif : KAFKA_CLIENT_KEYSTORE, KAFKA_CLIENT_KEYSTORE_PASSWORD, KAFKA_CLIENT_KEY_PASSWORD, ENCRYPTED_KAFKA_CLIENT_KEYSTORE_PASSWORD, ENCRYPTED_KAFKA_CLIENT_KEY_PASSWORD. Ces paramètres sont utilisés pour configurer la configuration client TLS avec SSL dans KAFKA.
- Facultatif : KAFKA_SASL_MECHANISM. Peut être spécifié comme suit : SCRAM-SHA-512, GSSAPI ou AWS_MSK_IAM.
- Facultatif : KAFKA_SASL_SCRAM_USERNAME, KAFKA_SASL_SCRAM_PASSWORD, ENCRYPTED_KAFKA_SASL_SCRAM_PASSWORD. Ces paramètres sont utilisés pour configurer l'authentification SASL/SCRAMSHA-512 avec KAFKA.
- Facultatif : KAFKA_SASL_GSSAPI_KEYTAB, KAFKA_SASL_GSSAPI_KRB5_CONF, KAFKA_SASL_GSSAPI_SERVICE, KAFKA_SASL_GSSAPI_PRINCIPAL. Ces paramètres sont utilisés pour configurer l'authentification SASL/GSSAPI avec KAFKA.
- MONGODB - Désigne une connexion à une base de données de documents MongoDB.

MONGODB Les connexions utilisent les méthodes suivantes ConnectionParameters.

- Obligatoire : CONNECTION_URL.
- Obligatoire : toutes les valeurs (USERNAME, PASSWORD) ou SECRET_ID.
- VIEW_VALIDATION_REDSHIFT- Désigne une connexion utilisée pour la validation des vues par Amazon Redshift.

- **VIEW_VALIDATION_ATHENA**- Désigne une connexion utilisée pour la validation des vues par Amazon Athena.
- **NETWORK** - Désigne une connexion réseau à une source de données dans un environnement Amazon Virtual Private Cloud (Amazon VPC).

NETWORK Les connexions ne sont pas nécessaires `ConnectionParameters`. Fournissez plutôt un `PhysicalConnectionRequirements`.

- **MARKETPLACE**- Utilise les paramètres de configuration contenus dans un connecteur acheté AWS Marketplace pour lire et écrire dans des magasins de données qui ne sont pas pris en charge de manière native par AWS Glue.

MARKETPLACE Les connexions utilisent les méthodes suivantes `ConnectionParameters`.

- Obligatoire : `CONNECTOR_TYPE`, `CONNECTOR_URL`, `CONNECTOR_CLASS_NAME`, `CONNECTION_URL`.
- Obligatoire pour les connexions JDBC `CONNECTOR_TYPE` : toutes les valeurs (`USERNAME`, `PASSWORD`) ou `SECRET_ID`.
- **CUSTOM** - Utilise les paramètres de configuration contenus dans un connecteur personnalisé pour lire et écrire dans des magasins de données qui ne sont pas pris en charge en mode natif par AWS Glue.

En outre, `ConnectionType` les connecteurs SaaS suivants sont pris en charge :

- **FACEBOOKADS**- Désigne une connexion aux publicités Facebook.
- **GOOGLEADS**- Désigne une connexion à Google Ads.
- **GOOGLESHEETS**- Désigne une connexion à Google Sheets.
- **GOOGLEANALYTICS4**- Désigne une connexion à Google Analytics 4.
- **HUBSPOT**- Désigne une connexion à HubSpot.
- **INSTAGRAMADS**- Désigne une connexion aux publicités Instagram.
- **INTERCOM**- Désigne une connexion à Intercom.
- **JIRACLOUD**- Désigne une connexion à Jira Cloud.
- **MARKETO**- Désigne une connexion à Adobe Marketo Engage.
- **NETSUITEERP**- Désigne une connexion à Oracle NetSuite.
- **SALESFORCE**- Désigne une connexion à Salesforce à l'aide de l' OAuth authentification.
- **SALESFORCEMARKETINGCLOUD**- Désigne une connexion à Salesforce Marketing Cloud.

- SALESFORCEPARDOT- Désigne une connexion à Salesforce Marketing Cloud Account Engagement (MCAE).
- SAP0DATA- Désigne une connexion à SAP OData.
- SERVICENOW- Désigne une connexion à ServiceNow
- SLACK- Désigne une connexion à Slack.
- SNAPCHATADS- Désigne une connexion à Snapchat Ads.
- STRIPE- Désigne une connexion à Stripe.
- ZENDESK- Désigne une connexion à Zendesk.
- ZOHOCRM- Désigne une connexion à Zoho CRM.

Pour plus d'informations sur les paramètres de connexion nécessaires pour un connecteur particulier, consultez la documentation du connecteur dans la section [Ajouter une AWS Glue connexion](#) dans le guide de AWS Glue l'utilisateur.

SFTP n'est pas pris en charge.

Pour plus d'informations sur la manière dont les fonctionnalités facultatives ConnectionProperties sont utilisées pour configurer les fonctionnalités dans AWS Glue, consultez les [propriétés de AWS Glue connexion](#).

Pour plus d'informations sur la manière dont ConnectionProperties les options sont utilisées pour configurer les fonctionnalités dans AWS Glue Studio, consultez [Utilisation de connecteurs et de connexions](#).

- MatchCriteria – Tableau de chaînes UTF-8, avec 10 chaînes maximum.

Liste des critères qui peuvent être utilisés dans la sélection de cette connexion.

- ConnectionProperties – Obligatoire : Tableau de mappage de paires clé-valeur, avec 100 paires au maximum.

Chaque clé est une chaîne UTF-8 (valeurs valides : HOST | PORT | USERNAME="USER_NAME" | PASSWORD | ENCRYPTED_PASSWORD | JDBC_DRIVER_JAR_URI | JDBC_DRIVER_CLASS_NAME | JDBC_ENGINE | JDBC_ENGINE_VERSION | CONFIG_FILES | INSTANCE_ID | JDBC_CONNECTION_URL | JDBC_ENFORCE_SSL | CUSTOM_JDBC_CERT | SKIP_CUSTOM_JDBC_CERT_VALIDATION | CUSTOM_JDBC_CERT_STRING | CONNECTION_URL | KAFKA_BOOTSTRAP_SERVERS | KAFKA_SSL_ENABLED | KAFKA_CUSTOM_CERT | KAFKA_SKIP_CUSTOM_CERT_VALIDATION |

KAFKA_CLIENT_KEYSTORE | KAFKA_CLIENT_KEYSTORE_PASSWORD |
 KAFKA_CLIENT_KEY_PASSWORD | ENCRYPTED_KAFKA_CLIENT_KEYSTORE_PASSWORD
 | ENCRYPTED_KAFKA_CLIENT_KEY_PASSWORD | KAFKA_SASL_MECHANISM
 | | KAFKA_SASL_PLAIN_USERNAME | KAFKA_SASL_PLAIN_PASSWORD |
 ENCRYPTED_KAFKA_SASL_PLAIN_PASSWORD | KAFKA_SASL_SCRAM_USERNAME
 | KAFKA_SASL_SCRAM_PASSWORD | KAFKA_SASL_SCRAM_SECRETS_ARN |
 ENCRYPTED_KAFKA_SASL_SCRAM_PASSWORD KAFKA_SASL_GSSAPI_KEYTAB
 KAFKA_SASL_GSSAPI_KRB5_CONF | KAFKA_SASL_GSSAPI_SERVICE |
 KAFKA_SASL_GSSAPI_PRINCIPAL SECRET_ID | CONNECTOR_URL | CONNECTOR_TYPE
 | CONNECTOR_CLASS_NAME | ENDPOINT | ENDPOINT_TYPE | ROLE_ARN | REGION
 WORKGROUP_NAME | CLUSTER_IDENTIFIER | DATABASE).

Chaque valeur est une chaîne de valeurs d'une longueur d'au moins 1 octet ou supérieure à 1 024 octets.

Ces paires clé-valeur définissent les paramètres pour la connexion.

- `SparkProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 2 048 octets.

Propriétés de connexion spécifiques à l'environnement informatique Spark.

- `AthenaProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 2 048 octets.

Propriétés de connexion spécifiques à l'environnement informatique Athena.

- `PythonProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 2 048 octets.

Propriétés de connexion spécifiques à l'environnement de calcul Python.

- `PhysicalConnectionRequirements` – Un objet [PhysicalConnectionRequirements](#).

Les exigences de connexion physique, telles que le cloud privé virtuel (VPC) et `SecurityGroup`, qui sont nécessaires pour établir correctement cette connexion.

- `AuthenticationConfiguration` – Un objet [AuthenticationConfigurationInput](#).

Les propriétés d'authentification de la connexion.

- `ValidateCredentials` – Booléen.

Un drapeau pour valider les informations d'identification lors de la création de la connexion. La valeur par défaut est `true`.

- `ValidateForComputeEnvironments` – Tableau de chaînes UTF-8.

Environnements de calcul par rapport auxquels les propriétés de connexion spécifiées sont validées.

TestConnectionInput structure

Structure utilisée pour spécifier le test d'une connexion à un service.

Champs

- `ConnectionType`— Obligatoire : chaîne UTF-8 (valeurs valides : `JDBC` | `SFTP` | `MONGODB` | `KAFKA` | `NETWORK` | `MARKETPLACE` | `CUSTOM` | `SALESFORCE` | `VIEW_VALIDATION_REDSHIFT` | `VIEW_VALIDATION_ATHENA` | `GOOGLEADS` | `GOOGLESHEETS` | `GOOGLEANALYTICS4` | `SERVICENOW` | `MARKETO` | `SAPODATA` | `ZENDESK` | `JIRACLOUD` | `NETSUITEERP` | `HUBSPOT` | `FACEBOOKADS` | `INSTAGRAMADS` | `ZOHOCRIM` | `SALESFORCEPARDOT` | `SALESFORCEMARKETINGCLOUD` | `SLACK` | `STRIPE` | `INTERCOM` | `SNAPCHATADS`).

Type de connexion à tester. Cette opération n'est disponible que pour les types de `SALESFORCE` connexion `JDBC` ou.

- `ConnectionProperties` – Obligatoire : Tableau de mappage de paires clé-valeur, avec 100 paires au maximum.

Chaque clé est une chaîne UTF-8 (valeurs valides : `HOST` | `PORT` | `USERNAME="USER_NAME"` | `PASSWORD` | `ENCRYPTED_PASSWORD` | `JDBC_DRIVER_JAR_URI` | `JDBC_DRIVER_CLASS_NAME` | `JDBC_ENGINE` | `JDBC_ENGINE_VERSION` | `CONFIG_FILES` | `INSTANCE_ID` | `JDBC_CONNECTION_URL` | `JDBC_ENFORCE_SSL` | `CUSTOM_JDBC_CERT` | `SKIP_CUSTOM_JDBC_CERT_VALIDATION` | `CUSTOM_JDBC_CERT_STRING` |

| CONNECTION_URL | KAFKA_BOOTSTRAP_SERVERS | KAFKA_SSL_ENABLED
 | KAFKA_CUSTOM_CERT | KAFKA_SKIP_CUSTOM_CERT_VALIDATION |
 KAFKA_CLIENT_KEYSTORE | KAFKA_CLIENT_KEYSTORE_PASSWORD |
 KAFKA_CLIENT_KEY_PASSWORD | ENCRYPTED_KAFKA_CLIENT_KEYSTORE_PASSWORD
 | ENCRYPTED_KAFKA_CLIENT_KEY_PASSWORD | KAFKA_SASL_MECHANISM
 | | KAFKA_SASL_PLAIN_USERNAME | KAFKA_SASL_PLAIN_PASSWORD |
 ENCRYPTED_KAFKA_SASL_PLAIN_PASSWORD | KAFKA_SASL_SCRAM_USERNAME
 | KAFKA_SASL_SCRAM_PASSWORD | KAFKA_SASL_SCRAM_SECRETS_ARN |
 ENCRYPTED_KAFKA_SASL_SCRAM_PASSWORD KAFKA_SASL_GSSAPI_KEYTAB
 KAFKA_SASL_GSSAPI_KRB5_CONF | KAFKA_SASL_GSSAPI_SERVICE |
 KAFKA_SASL_GSSAPI_PRINCIPAL SECRET_ID | CONNECTOR_URL | CONNECTOR_TYPE
 | CONNECTOR_CLASS_NAME | ENDPOINT | ENDPOINT_TYPE | ROLE_ARN | REGION
 WORKGROUP_NAME | CLUSTER_IDENTIFIER | DATABASE).

Chaque valeur est une chaîne de valeurs d'une longueur d'au moins 1 octet ou supérieure à 1 024 octets.

Les paires clé-valeur qui définissent les paramètres de la connexion.

Les connexions JDBC utilisent les propriétés de connexion suivantes :

- Obligatoire : toutes les valeurs (HOST, PORT, JDBC_ENGINE) ou JDBC_CONNECTION_URL.
- Obligatoire : toutes les valeurs (USERNAME, PASSWORD) ou SECRET_ID.
- Facultatif : JDBC_ENFORCE_SSL, CUSTOM_JDBC_CERT, CUSTOM_JDBC_CERT_STRING, SKIP_CUSTOM_JDBC_CERT_VALIDATION. Ces paramètres sont utilisés pour configurer le SSL avec JDBC.

Les connexions SALESFORCE nécessitent que le AuthenticationConfiguration membre soit configuré.

- AuthenticationConfiguration – Un objet [AuthenticationConfigurationInput](#).

Structure contenant la configuration d'authentification dans la TestConnection demande.
 Nécessaire pour une connexion à Salesforce à l'aide de OAuth l'authentification.

PhysicalConnectionRequirements structure

L'application OAuth cliente en GetConnection réponse.

Champs

- **SubnetId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de sous-réseau utilisé par la connexion.

- **SecurityGroupIdList** – Tableau de chaînes UTF-8, avec 50 chaînes maximum.

Liste des ID de groupe de sécurité utilisée par la connexion.

- **AvailabilityZone** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Connexion de la zone de disponibilité.

GetConnectionsFilter structure

Filtre les définitions de connexion retournées par l'opération d'API `GetConnections`.

Champs

- **MatchCriteria** – Tableau de chaînes UTF-8, avec 10 chaînes maximum.

Chaîne des critères qui doivent répondre aux critères enregistrés dans la définition de connexion pour que cette définition soit renvoyée.

- **ConnectionType**— Chaîne UTF-8 (valeurs valides : JDBC | SFTP | MONGODB | KAFKA | NETWORK | MARKETPLACE | CUSTOM | SALESFORCE | VIEW_VALIDATION_REDSHIFT | VIEW_VALIDATION_ATHENA | GOOGLEADS | GOOGLESHEETS | GOOGLEANALYTICS4 | SERVICENOW | MARKETO | SAPODATA | ZENDESK | JIRACLOUD | NETSUITEERP | HUBSPOT | FACEBOOKADS | INSTAGRAMADS | ZOHOCRm | SALESFORCEPARDOT | SALESFORCEMARKETINGCLOUD | SLACK STRIPE INTERCOM | SNAPCHATADS).

Type de connexions à renvoyer. Actuellement, SFTP n'est pas pris en charge.

- **ConnectionSchemaVersion**— Nombre (entier), pas moins de 1 ou plus de 2.

Indique si la connexion a été créée avec la version 1 ou 2 du schéma.

AuthenticationConfiguration structure

Structure contenant la configuration d'authentification.

Champs

- `AuthenticationType` – Chaîne UTF-8 (valeurs valides : BASIC | OAUTH2 | CUSTOM | IAM).

Structure contenant la configuration d'authentification.

- `SecretArn` – Chaîne UTF-8, correspondant au [Custom string pattern #36](#).

L'ARN du gestionnaire secret pour stocker les informations d'identification.

- `KmsKeyArn` – Chaîne UTF-8, correspondant au [Custom string pattern #29](#).

Le nom de ressource Amazon (ARN) de la clé KMS utilisée pour chiffrer les informations d'authentification sensibles. Cette clé est utilisée pour protéger les informations d'identification et autres données sensibles stockées dans la configuration d'authentification.

- `OAuth2Properties` – Un objet [OAuth2Propriétés](#).

Les propriétés de l' OAuth2 authentification.

AuthenticationConfigurationInput structure

Structure contenant la configuration d'authentification dans la CreateConnection demande.

Champs

- `AuthenticationType` – Chaîne UTF-8 (valeurs valides : BASIC | OAUTH2 | CUSTOM | IAM).

Structure contenant la configuration d'authentification dans la CreateConnection demande.

- `OAuth2Properties` – Un objet [OAuth2PropertiesInput](#).

Les propriétés d' OAuth2 authentification dans la CreateConnection demande.

- `SecretArn` – Chaîne UTF-8, correspondant au [Custom string pattern #36](#).

L'ARN du gestionnaire secret pour stocker les informations d'identification dans la CreateConnection demande.

- `KmsKeyArn` – Chaîne UTF-8, correspondant au [Custom string pattern #29](#).

L'ARN de la clé KMS utilisée pour chiffrer la connexion. Utilisée uniquement comme entrée dans la demande et stockée dans le gestionnaire de secrets.

- `BasicAuthenticationCredentials` – Un objet [BasicAuthenticationCredentials](#).

Les informations d'identification utilisées lorsque le type d'authentification est une authentification de base.

- `CustomAuthenticationCredentials` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 2 048 octets.

Les informations d'identification utilisées lorsque le type d'authentification est une authentification personnalisée.

OAuth2Structure des propriétés

Structure contenant les propriétés d' OAuth2 authentification.

Champs

- `OAuth2GrantType` – Chaîne UTF-8 (valeurs valides : `AUTHORIZATION_CODE` | `CLIENT_CREDENTIALS` | `JWT_BEARER`).

Le type de OAuth2 subvention. Par exemple, `AUTHORIZATION_CODE`, `JWT_BEARER` ou `CLIENT_CREDENTIALS`.

- `OAuth2ClientApplication` – Un objet [OAuth2ClientApplication](#).

Type d'application client. Par exemple, `AWS_MANAGED` ou `USER_MANAGED`.

- `TokenUrl` – chaîne UTF-8, d'une longueur ne dépassant pas 256 octets, correspondant au [Custom string pattern #40](#).

URL du serveur d'authentification du fournisseur, pour échanger un code d'autorisation contre un jeton d'accès.

- `TokenUrlParametersMap` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8 d'une longueur d'au moins 1 octet ou supérieure à 512 octets.

Carte des paramètres ajoutés à la GET demande de jeton.

OAuth2PropertiesInput structure

Structure contenant les propriétés OAuth2 de la CreateConnection demande.

Champs

- `OAuth2GrantType` – Chaîne UTF-8 (valeurs valides : `AUTHORIZATION_CODE` | `CLIENT_CREDENTIALS` | `JWT_BEARER`).

Type de OAuth2 subvention indiqué dans la CreateConnection demande. Par exemple, `AUTHORIZATION_CODE`, `JWT_BEARER` ou `CLIENT_CREDENTIALS`.

- `OAuth2ClientApplication` – Un objet [OAuth2ClientApplication](#).

Type d'application client dans la CreateConnection demande. Par exemple, `AWS_MANAGED` ou `USER_MANAGED`.

- `TokenUrl` – chaîne UTF-8, d'une longueur ne dépassant pas 256 octets, correspondant au [Custom string pattern #40](#).

URL du serveur d'authentification du fournisseur, pour échanger un code d'autorisation contre un jeton d'accès.

- `TokenUrlParametersMap` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8 d'une longueur d'au moins 1 octet ou supérieure à 512 octets.

Carte des paramètres ajoutés à la GET demande de jeton.

- `AuthorizationCodeProperties` – Un objet [AuthorizationCodeProperties](#).

Ensemble de propriétés requis pour le type de OAuth2 `AUTHORIZATION_CODE` subvention.

- `OAuth2Credentials` – Un objet [OAuth2Informations d'identification](#).

Les informations d'identification utilisées lorsque le type d'authentification est OAuth2 l'authentification.

OAuth2ClientApplication structure

L'application OAuth2 cliente utilisée pour la connexion.

Champs

- `UserManagedClientApplicationClientId` – Chaîne UTF-8, d'une longueur maximale de 2 048 octets, correspondant au [Custom string pattern #37](#).

ClientID de l'application clientId si c'est le cas. ClientAppType USER_MANAGED

- `AWSManagedClientApplicationReference` – Chaîne UTF-8, d'une longueur maximale de 2 048 octets, correspondant au [Custom string pattern #37](#).

La référence à l'application cliente côté SaaS qui est AWS gérée.

AuthorizationCodeProperties structure

Ensemble de propriétés requis pour le flux de travail du type de OAuth2 AUTHORIZATION_CODE subvention.

Champs

- `AuthorizationCode`— Chaîne UTF-8, d'au moins 1 ou plus de 4 096 octets, correspondant au. [Custom string pattern #37](#)

Code d'autorisation à utiliser dans la troisième étape du processus de AUTHORIZATION_CODE subvention. Il s'agit d'un code à usage unique qui devient invalide une fois échangé contre un jeton d'accès. Il est donc acceptable d'avoir cette valeur comme paramètre de demande.

- `RedirectUri`— Chaîne UTF-8, d'une longueur maximale de 512 octets, correspondant au. [Custom string pattern #41](#)

L'URI de redirection vers laquelle l'utilisateur est redirigé par le serveur d'autorisation lors de l'émission d'un code d'autorisation. L'URI est ensuite utilisé lorsque le code d'autorisation est échangé contre un jeton d'accès.

BasicAuthenticationCredentials structure

Pour fournir des informations d'authentification de base lorsque vous ne fournissez pas de `SecretArn` valeur.

Champs

- `Username`— Chaîne UTF-8, d'une longueur maximale de 512 octets, correspondant au. [Custom string pattern #37](#)

Le nom d'utilisateur pour se connecter à la source de données.

- Password— Chaîne UTF-8, d'une longueur maximale de 512 octets, correspondant au. [Custom string pattern #33](#)

Le mot de passe pour se connecter à la source de données.

OAuth2Structure des informations d'identification

Les informations d'identification utilisées lorsque le type d'authentification est OAuth2 l'authentification.

Champs

- UserManagedClientApplicationClientSecret— Chaîne UTF-8, d'une longueur maximale de 512 octets, correspondant au. [Custom string pattern #38](#)

Le secret client de l'application cliente si l'application client est gérée par l'utilisateur.

- AccessToken— Chaîne UTF-8, d'une longueur maximale de 4096 octets, correspondant au. [Custom string pattern #38](#)

Le jeton d'accès utilisé lorsque le type d'authentification est OAuth2.

- RefreshToken— Chaîne UTF-8, d'une longueur maximale de 4096 octets, correspondant au. [Custom string pattern #38](#)

Le jeton d'actualisation utilisé lorsque le type d'authentification est OAuth2.

- JwtToken— Chaîne UTF-8, d'une longueur maximale de 8 000 octets, correspondant au. [Custom string pattern #39](#)

Le jeton Web JSON (JWT) utilisé lorsque le type d'authentification est OAuth2.

Opérations

- [CreateConnection action \(Python : créer connexion\)](#)
- [DeleteConnection action \(Python : supprimer connexion\)](#)
- [GetConnection action \(Python : get_connection\)](#)
- [GetConnections action \(Python : get_connections\)](#)

- [UpdateConnection action \(Python : update_connection\)](#)
- [TestConnection action \(Python : test_connection\)](#)
- [BatchDeleteConnection action \(Python : batch_delete_connection\)](#)

CreateConnection action (Python : créer_connexion)

Crée une définition de connexion dans le catalogue de données.

Les connexions utilisées pour créer des ressources fédérées nécessitent l'autorisation IAM `glue:PassConnection`.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel créer la connexion. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `ConnectionInput` – Obligatoire : un objet [ConnectionInput](#).

Objet `ConnectionInput` définissant la connexion à créer.

- `Tags` – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Les identifications que vous attribuez à la connexion.

Réponse

- `CreateConnectionStatus` – Chaîne UTF-8 (valeurs valides : `READY` | `IN_PROGRESS` | `FAILED`).

État de la demande de création de connexion. La demande peut prendre un certain temps pour certains types d'authentification, par exemple lors de la création d'une OAuth connexion avec échange de jetons via VPC.

Erreurs

- `AlreadyExistsException`
- `InvalidInputException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `GlueEncryptionException`

DeleteConnection action (Python : `supprimer_connexion`)

Supprime une connexion du catalogue de données.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la connexion. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `ConnectionName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la connexion à supprimer.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `OperationTimeoutException`

GetConnection action (Python : `get_connection`)

Extrait une définition de connexion du catalogue de données.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la connexion. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de connexion à extraire.

- `HidePassword` – Booléen.

Vous permet de récupérer les métadonnées de connexion sans renvoyer le mot de passe. Par exemple, la AWS Glue console utilise cet indicateur pour récupérer la connexion et n'affiche pas le mot de passe. Définissez ce paramètre lorsque l'appelant n'est peut-être pas autorisé à utiliser la AWS KMS clé pour déchiffrer le mot de passe, mais qu'il est autorisé à accéder au reste des propriétés de connexion.

- `ApplyOverrideForComputeEnvironment` – Chaîne UTF-8 (valeurs valides : SPARK | ATHENA | PYTHON).

Pour les connexions qui peuvent être utilisées dans plusieurs services, spécifie les propriétés de renvoi pour l'environnement de calcul spécifié.

Réponse

- `Connection` – Un objet [Connexion](#).

Définition de connexion demandée.

Erreurs

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`

GetConnections action (Python : `get_connections`)

Extrait une liste de définitions de connexion du catalogue de données.

Demande

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel résident les connexions. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- **Filter** – Un objet [GetConnectionsFilter](#).

Filtre qui contrôle les connexions à renvoyer.

- **HidePassword** – Booléen.

Vous permet de récupérer les métadonnées de connexion sans renvoyer le mot de passe. Par exemple, la AWS Glue console utilise cet indicateur pour récupérer la connexion et n'affiche pas le mot de passe. Définissez ce paramètre lorsque l'appelant n'est peut-être pas autorisé à utiliser la AWS KMS clé pour déchiffrer le mot de passe, mais qu'il est autorisé à accéder au reste des propriétés de connexion.

- **NextToken** – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

- **MaxResults** – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de connexions à renvoyer dans une réponse.

Réponse

- **ConnectionList** – Un tableau d'objets [Connexion](#).

Liste des définitions de connexion demandées.

- **NextToken** – Chaîne UTF-8.

Jeton de continuation, si la liste des connexions renvoyées n'inclut pas la dernière connexion filtrée.

Erreurs

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`

UpdateConnection action (Python : `update_connection`)

Met à jour une définition de connexion dans le catalogue de données.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la connexion. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de connexion à mettre à jour.

- `ConnectionInput` – Obligatoire : un objet [ConnectionInput](#).

Objet `ConnectionInput` qui redéfinit la connexion en question.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`

TestConnection action (Python : test_connection)

Teste une connexion à un service pour valider les informations d'identification du service que vous fournissez.

Vous pouvez fournir un nom de connexion existant ou un TestConnectionInput pour tester une entrée de connexion inexistante. Fournir les deux en même temps provoquera une erreur.

Si l'action aboutit, le service renvoie une réponse HTTP 200.

Demande

- **ConnectionName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Facultatif. Nom de la connexion à tester. Si seul le nom est fourni, l'opération obtiendra la connexion et l'utilisera pour les tests.

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID du catalogue où réside la connexion.

- **TestConnectionInput** – Un objet [TestConnectionInput](#).

Structure utilisée pour spécifier le test d'une connexion à un service.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `InvalidInputException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `GlueEncryptionException`
- `FederationSourceException`
- `AccessDeniedException`

- `EntityNotFoundException`
- `ConflictException`
- `InternalServiceException`

BatchDeleteConnection action (Python : `batch_delete_connection`)

Supprime une liste de définitions de connexion du catalogue de données.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel résident les connexions. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `ConnectionNameList` – Obligatoire : Tableau de chaînes UTF-8, avec 25 chaînes maximum.

Liste des noms des connexions à supprimer.

Réponse

- `Succeeded` – Tableau de chaînes UTF-8.

Liste des noms des définitions de connexion qui ont été supprimées avec succès.

- `Errors` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est un objet [ErrorDetail](#).

Carte des noms des connexions qui n'ont pas été supprimées avec succès pour les détails d'erreur.

Erreurs

- `InternalServiceException`
- `OperationTimeoutException`

API des types de connexion

L'API Connection Type décrit AWS Glue APIs la description des types de connexion.

Gestion des connexions APIs

- [DescribeConnectionType action \(Python : describe_connection_type\)](#)
- [ListConnectionTypes action \(Python : list_connection_types\)](#)
- [ConnectionTypeBrief structure](#)
- [ConnectionTypeVariant structure](#)

DescribeConnectionType action (Python : describe_connection_type)

L'DescribeConnectionTypeAPI fournit des informations complètes sur les options prises en charge pour un type de connexion donné dans AWS Glue.

Demande

- **ConnectionType** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du type de connexion à décrire.

Réponse

- **ConnectionType** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du type de connexion.

- **Description**— Chaîne UTF-8 d'une longueur maximale de 1024 octets.

Description du type de connexion.

- **Capabilities** – Un objet [Fonctionnalités](#).

Les types d'authentification, les types d'interface de données (environnements informatiques) et les opérations de données pris en charge par le connecteur.

- **ConnectionProperties** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est un objet [Propriété](#).

Propriétés de connexion communes à tous les environnements informatiques.

- `ConnectionOptions` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est un objet [Propriété](#).

Renvoie les propriétés qui peuvent être définies lors de la création d'une connexion dans `leConnectionInput.ConnectionProperties`. `ConnectionOptions` définit les paramètres qui peuvent être définis dans un script Spark ETL dans la carte des options de connexion transmise à une trame de données.

- `AuthenticationConfiguration` – Un objet [AuthConfiguration](#).

Type d'authentification utilisé pour la connexion.

- `ComputeEnvironmentConfigurations` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est un objet [ComputeEnvironmentConfiguration](#).

Les environnements informatiques pris en charge par la connexion.

- `PhysicalConnectionRequirements` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est un objet [Propriété](#).

Exigences physiques pour une connexion, telles que les spécifications du VPC, du sous-réseau et du groupe de sécurité.

- `AthenaConnectionProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est un objet [Propriété](#).

Propriétés de connexion spécifiques à l'environnement informatique Athena.

- `PythonConnectionProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est un objet [Propriété](#).

Propriétés de connexion spécifiques à l'environnement de calcul Python.

- `SparkConnectionProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est un objet [Propriété](#).

Propriétés de connexion spécifiques à l'environnement informatique Spark.

Erreurs

- `ValidationException`
- `InvalidInputException`
- `InternalServiceException`

ListConnectionTypes action (Python : `list_connection_types`)

L'`ListConnectionTypesAPI` fournit un mécanisme de découverte permettant de connaître les types de connexion disponibles dans AWS Glue. La réponse contient une liste de types de connexion avec des informations détaillées sur ce qui est pris en charge pour chaque type de connexion. Les types de connexion répertoriés sont l'ensemble des options prises en charge pour la `ConnectionType` valeur dans l'`CreateConnectionAPI`.

Demande

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats à renvoyer.

- `NextToken` – Chaîne UTF-8, d'une longueur comprise entre 1 et 2048 octets, correspondant au [Custom string pattern #11](#).

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- `ConnectionTypes` – Un tableau d'objets [ConnectionTypeBrief](#).

Liste d'`ConnectionTypeBrief` objets contenant de brèves informations sur les types de connexion pris en charge.

- `NextToken` – Chaîne UTF-8, d'une longueur comprise entre 1 et 2048 octets, correspondant au [Custom string pattern #11](#).

Un jeton de continuation, si le segment de liste actuel n'est pas le dernier.

Erreurs

- `InternalServiceException`

ConnectionTypeBrief structure

Brèves informations sur un type de connexion pris en charge renvoyées par `ListConnectionTypesAPI`.

Champs

- `ConnectionType`— Chaîne UTF-8 (valeurs valides : `JDBC` | `SFTP` | `MONGODB` | `KAFKA` | `NETWORK` | `MARKETPLACE` | `CUSTOM` | `SALESFORCE` | `VIEW_VALIDATION_REDSHIFT` | `VIEW_VALIDATION_ATHENA` | `GOOGLEADS` | `GOOGLESHEETS` | `GOOGLEANALYTICS4` | `SERVICENOW` | `MARKETO` | `SAPODATA` | `ZENDESK` | `JIRACLOUD` | `NETSUITEERP` | `HUBSPOT` | `FACEBOOKADS` | `INSTAGRAMADS` | `ZOHOCRm` | `SALESFORCEPARDOT` | `SALESFORCEMARKETINGCLOUD` | `SLACK` | `STRIPE` | `INTERCOM` | `SNAPCHATADS`).

Nom du type de connexion.

- `DisplayName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Le nom lisible par l'homme du type de connexion affiché dans la AWS Glue console.

- `Vendor` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Le nom du fournisseur ou du fournisseur qui a créé ou gère ce type de connexion.

- `Description`— Chaîne UTF-8 d'une longueur maximale de 1024 octets.

Description du type de connexion.

- **Categories** – Tableau de chaînes UTF-8.

Liste des catégories auxquelles appartient ce type de connexion. Les catégories aident les utilisateurs à filtrer et à trouver les types de connexion appropriés en fonction de leurs cas d'utilisation.

- **Capabilities** – Un objet [Fonctionnalités](#).

Les types d'authentification, les types d'interface de données (environnements informatiques) et les opérations de données pris en charge par le connecteur.

- **LogoUrl** – Chaîne UTF-8.

URL du logo associé à un type de connexion.

- **ConnectionTypeVariants** – Un tableau d'objets [ConnectionTypeVariant](#).

Liste des variantes disponibles pour ce type de connexion. Différentes variantes peuvent fournir des configurations spécialisées pour des cas d'utilisation spécifiques ou des implémentations du même type de connexion général.

ConnectionTypeVariant structure

Représente une variante d'un type de connexion dans le catalogue de AWS Glue données. Les variantes de type de connexion fournissent des configurations et des comportements spécifiques pour différentes implémentations du même type de connexion général.

Champs

- **ConnectionTypeVariantName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Identifiant unique pour la variante du type de connexion. Ce nom est utilisé en interne pour identifier la variante spécifique d'un type de connexion.

- **DisplayName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Le nom lisible par l'homme de la variante de type de connexion qui s'affiche dans la AWS Glue console.

- **Description**— Chaîne UTF-8 d'une longueur maximale de 1024 octets.

Description détaillée de la variante du type de connexion, y compris son objectif, ses cas d'utilisation et les exigences de configuration spécifiques.

- `LogoUrl` – Chaîne UTF-8.

URL du logo associé à une variante de type de connexion.

types de données

- [Structure de validation](#)
- [AuthConfiguration structure](#)
- [Structure des capacités](#)
- [Structure de la propriété](#)
- [AllowedValue structure](#)
- [ComputeEnvironmentConfiguration structure](#)

Structure de validation

Définit la manière dont une validation est effectuée sur une propriété de connexion.

Champs

- `ValidationType` – Obligatoire : Chaîne UTF-8 (valeurs valides : REGEX | RANGE).

Le type de validation à effectuer, tel que REGEX.

- `Patterns` – Tableau de chaînes UTF-8.

Liste des modèles qui s'appliquent à la validation.

- `Description`— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de 1 024 octets.

Description de la validation.

- `MaxLength` – Nombre (entier).

Longueur maximale d'une propriété de connexion sous forme de chaîne.

- `Maximum` – Nombre (entier).

Valeur maximale lors de la spécification d'un RANGE type de validation.

- `Minimum` – Nombre (entier).

Une valeur minimale lors de la spécification d'un RANGE type de validation.

AuthConfiguration structure

Configuration d'authentification pour une connexion renvoyée par l'`DescribeConnectionTypeAPI`.

Champs

- `AuthenticationType` – Obligatoire : un objet [Propriété](#).

Type d'authentification pour une connexion.

- `SecretArn` – Un objet [Propriété](#).

Le nom de ressource Amazon (ARN) pour le Secrets Manager.

- `OAuth2Properties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est un objet [Propriété](#).

Une carte des paires clé-valeur pour les OAuth2 propriétés. Chaque valeur est un Property objet.

- `BasicAuthenticationProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est un objet [Propriété](#).

Une carte des paires clé-valeur pour les OAuth2 propriétés. Chaque valeur est un Property objet.

- `CustomAuthenticationProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est un objet [Propriété](#).

Carte des paires clé-valeur pour les propriétés d'authentification personnalisées. Chaque valeur est un Property objet.

Structure des capacités

Spécifie les types d'authentification pris en charge renvoyés par l'`DescribeConnectionTypeAPI`.

Champs

- `SupportedAuthenticationTypes` – Obligatoire : Tableau de chaînes UTF-8.

Liste des types d'authentification pris en charge.

- `SupportedDataOperations` – Obligatoire : Tableau de chaînes UTF-8.

Liste des opérations de données prises en charge.

- `SupportedComputeEnvironments` – Obligatoire : Tableau de chaînes UTF-8.

Liste des environnements informatiques pris en charge.

Structure de la propriété

Objet qui définit un type de connexion pour un environnement informatique.

Champs

- `Name`— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Le nom de la propriété.

- `Description`— Obligatoire : chaîne UTF-8 d'une longueur maximale de 1024 octets.

Description de la propriété.

- `Required` – obligatoire : booléen.

Indique si la propriété est obligatoire.

- `DefaultValue` – Chaîne UTF-8.

La valeur par défaut de la propriété.

- `PropertyTypes` – Obligatoire : Tableau de chaînes UTF-8.

Décrit le type de propriété.

- `AllowedValues` – Un tableau d'objets [AllowedValue](#).

Liste d'`AllowedValue`objets représentant les valeurs autorisées pour la propriété.

- `DataOperationScopes` – Tableau de chaînes UTF-8.

Indique les opérations de données applicables à la propriété.

AllowedValue structure

Objet représentant une valeur autorisée pour une propriété.

Champs

- **Description**— Chaîne UTF-8 d'une longueur maximale de 1024 octets.

Description de la valeur autorisée.

- **Value**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Valeur autorisée pour la propriété.

ComputeEnvironmentConfiguration structure

Objet contenant la configuration d'un environnement informatique (tel que Spark, Python ou Athena) renvoyé par l'`DescribeConnectionTypeAPI`.

Champs

- **Name**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Nom de la configuration de l'environnement de calcul.

- **Description**— Obligatoire : chaîne UTF-8 d'une longueur maximale de 1024 octets.

Description de l'environnement informatique.

- **ComputeEnvironment** – Obligatoire : Chaîne UTF-8 (valeurs valides : SPARK | ATHENA | PYTHON).

Type d'environnement de calcul.

- **SupportedAuthenticationTypes** – Obligatoire : Tableau de chaînes UTF-8.

Les types d'authentification pris en charge pour l'environnement informatique.

- **ConnectionOptions** – obligatoire : tableau de mappage de paires clé-valeur.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est un objet [Propriété](#).

Les paramètres utilisés comme options de connexion pour l'environnement de calcul.

- `ConnectionPropertyNameOverrides` – obligatoire : tableau de mappage de paires clé-valeur.
Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.
Chaque valeur est une chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.
Le nom de la propriété de connexion est remplacé pour l'environnement de calcul.
- `ConnectionOptionNameOverrides` – obligatoire : tableau de mappage de paires clé-valeur.
Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.
Chaque valeur est une chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.
Le nom de l'option de connexion remplace celui de l'environnement informatique.
- `ConnectionPropertiesRequiredOverrides` – Obligatoire : Tableau de chaînes UTF-8.
Les propriétés de connexion requises en tant que remplacements pour l'environnement de calcul.
- `PhysicalConnectionPropertiesRequired` – Booléen.
Indique si `PhysicalConnectionProperties` elles sont requises pour l'environnement de calcul.

Métadonnées de connexion et API de prévisualisation

La connexion suivante APIs décrit les opérations permettant de décrire les métadonnées de connexion.

Types de données

- [Structure de l'entité](#)
- [Structure du champ](#)

Structure de l'entité

Une entité soutenue par une donnée `ConnectionType`.

Champs

- `EntityName` – Chaîne UTF-8.

Le nom de l'entité.

- **Label** – Chaîne UTF-8.

Libellé utilisé pour l'entité.

- **IsParentEntity** – Booléen.

Valeur booléenne qui permet de déterminer s'il existe des sous-objets pouvant être répertoriés.

- **Description** – Chaîne UTF-8.

Description de l'entité.

- **Category** – Chaîne UTF-8.

Type d'entités présentes dans la réponse. Cette valeur dépend de la connexion source. Par exemple, c'est `SObjects` pour Salesforce databases schemas et/ou tables pour des sources telles qu'Amazon Redshift.

- **CustomProperties** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Carte facultative de clés qui peut être renvoyée pour une entité par un connecteur.

Structure du champ

L'`Field` objet contient des informations sur les différentes propriétés associées à un champ dans le connecteur.

Champs

- **FieldName** – Chaîne UTF-8.

Identifiant unique pour le champ.

- **Label** – Chaîne UTF-8.

Une étiquette lisible utilisée pour le champ.

- **Description** – Chaîne UTF-8.

Description du champ.

- **FieldType**— Chaîne UTF-8 (valeurs valides : INT | SMALLINT | BIGINT | FLOAT | LONG | DATE | BOOLEAN | MAP | ARRAY | STRING | TIMESTAMP | DECIMAL | BYTE SHORT DOUBLE | STRUCT).

Type de données dans le champ.

- **IsPrimaryKey** – Booléen.

Indique si ce champ peut être utilisé comme clé primaire pour l'entité donnée.

- **IsNullable** – Booléen.

Indique si ce champ peut être nul ou non.

- **IsRetrievable** – Booléen.

Indique si ce champ peut être ajouté dans la clause Select de la requête SQL ou s'il est récupérable ou non.

- **IsFilterable** – Booléen.

Indique si ce champ peut être utilisé dans une clause de filtre (WHERE clause) d'une instruction SQL lors de l'interrogation de données.

- **IsPartitionable** – Booléen.

Indique si un champ donné peut être utilisé pour partitionner la requête envoyée au SaaS.

- **IsCreateable** – Booléen.

Indique si ce champ peut être créé dans le cadre d'une écriture de destination.

- **IsUpdateable** – Booléen.

Indique si ce champ peut être mis à jour dans le cadre d'une écriture de destination.

- **IsUpsertable** – Booléen.

Indique si ce champ peut être inséré dans le cadre d'une écriture de destination.

- **IsDefaultOnCreate** – Booléen.

Indique si ce champ est rempli automatiquement lors de la création de l'objet, par exemple s'il est créé à l'horodatage.

- **SupportedValues** – Tableau de chaînes UTF-8.

Liste des valeurs prises en charge pour le champ.

- `SupportedFilterOperators` – Tableau de chaînes UTF-8.

Indique les opérateurs de filtre pris en charge pour ce champ.

- `ParentField` – Chaîne UTF-8.

Nom de champ parent pour un champ imbriqué.

- `NativeDataType` – Chaîne UTF-8.

Type de données renvoyé par l'API SaaS, tel que « picklist » ou « textarea » de Salesforce.

- `CustomProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Carte facultative des clés qui peuvent être retournées.

Opérations

- [ListEntities action \(Python : `list\_entities`\)](#)
- [DescribeEntity action \(Python : `describe\_entity`\)](#)
- [GetEntityRecords action \(Python : `get\_entity\_records`\)](#)

ListEntities action (Python : `list_entities`)

Renvoie les entités disponibles prises en charge par le type de connexion.

Demande

- `ConnectionName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la connexion dont les informations d'identification sont requises pour interroger n'importe quel type de connexion.

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID du catalogue qui contient la connexion. Cela peut être nul. Par défaut, l'ID de AWS compte est l'ID du catalogue.

- ParentEntityName – Chaîne UTF-8.

Nom de l'entité parent pour laquelle vous souhaitez répertorier les enfants. Ce paramètre utilise un chemin entièrement qualifié de l'entité afin de répertorier les entités enfants.

- NextToken – Chaîne UTF-8, d'une longueur comprise entre 1 et 2048 octets, correspondant au [Custom string pattern #11](#).

Jeton de continuation, inclus s'il s'agit d'un appel de continuation.

- DataStoreApiVersion – Chaîne UTF-8, d'une longueur comprise entre 1 et 256 octets, correspondant au [Custom string pattern #23](#).

La version API du connecteur SaaS.

Réponse

- Entities – Un tableau d'objets [Entité](#).

Liste d'objets Entity.

- NextToken – Chaîne UTF-8, d'une longueur comprise entre 1 et 2048 octets, correspondant au [Custom string pattern #11](#).

Un jeton de continuation, présent si le segment en cours n'est pas le dernier.

Erreurs

- EntityNotFoundException
- OperationTimeoutException
- InvalidInputException
- GlueEncryptionException
- ValidationException
- FederationSourceException
- AccessDeniedException

DescribeEntity action (Python : describe_entity)

Fournit des détails concernant l'entité utilisée avec le type de connexion, avec une description du modèle de données pour chaque champ de l'entité sélectionnée.

La réponse inclut tous les champs qui constituent l'entité.

Demande

- **ConnectionName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la connexion qui contient les informations d'identification du type de connexion.

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID du catalogue qui contient la connexion. Cela peut être nul. Par défaut, l'ID de AWS compte est l'ID du catalogue.

- **EntityName** – Obligatoire : chaîne UTF-8.

Nom de l'entité que vous souhaitez décrire à partir du type de connexion.

- **NextToken** – Chaîne UTF-8, d'une longueur comprise entre 1 et 2048 octets, correspondant au [Custom string pattern #11](#).

Jeton de continuation, inclus s'il s'agit d'un appel de continuation.

- **DataStoreApiVersion** – Chaîne UTF-8, d'une longueur comprise entre 1 et 256 octets, correspondant au [Custom string pattern #23](#).

Version de l'API utilisée pour le magasin de données.

Réponse

- **Fields** – Un tableau d'objets [Champ](#).

Décrit les champs de cette entité de connecteur. Voici la liste des Field objets. Field est très similaire à une colonne dans une base de données. L'Field objet contient des informations sur les différentes propriétés associées aux champs du connecteur.

- **NextToken** – Chaîne UTF-8, d'une longueur comprise entre 1 et 2048 octets, correspondant au [Custom string pattern #11](#).

Un jeton de continuation, présent si le segment en cours n'est pas le dernier.

Erreurs

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`
- `ValidationException`
- `FederationSourceException`
- `AccessDeniedException`

GetEntityRecords action (Python : `get_entity_records`)

Cette API est utilisée pour interroger les données d'aperçu à partir d'un type de connexion donné ou d'un catalogue de AWS Glue données natif basé sur Amazon S3.

Renvoie les enregistrements sous la forme d'un tableau de blobs JSON. Chaque enregistrement est formaté à l'aide de Jackson en `JsonNode` fonction du type de champ défini par `DescribeEntityAPI`.

Les connecteurs Spark génèrent des schémas selon le même mappage de type de données que dans `DescribeEntityAPI`. Les connecteurs Spark convertissent les données en types de données appropriés correspondant au schéma lors du renvoi de lignes.

Demande

- `ConnectionName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la connexion qui contient les informations d'identification du type de connexion.

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID du catalogue qui contient la connexion. Cela peut être nul. Par défaut, l'ID de AWS compte est l'ID du catalogue.

- **EntityName** – Obligatoire : chaîne UTF-8.

Nom de l'entité à laquelle nous voulons interroger les données d'aperçu à partir du type de connexion donné.

- **NextToken** – Chaîne UTF-8, d'une longueur comprise entre 1 et 2048 octets, correspondant au [Custom string pattern #11](#).

Jeton de continuation, inclus s'il s'agit d'un appel de continuation.

- **DataStoreApiVersion** – Chaîne UTF-8, d'une longueur comprise entre 1 et 256 octets, correspondant au [Custom string pattern #23](#).

La version API du connecteur SaaS.

- **ConnectionOptions** – Tableau de mappage de paires clé-valeur, 100 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur d'au moins 1 ou de plus de 256 octets, correspondant au. [Custom string pattern #18](#)

Chaque valeur est une chaîne UTF-8, d'une longueur d'au moins 1 ou de plus de 256 octets, correspondant au. [Custom string pattern #17](#)

Options de connecteur requises pour interroger les données.

- **FilterPredicate**— Chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 100 000 octets.

Un prédicat de filtre que vous pouvez appliquer dans la demande de requête.

- **Limit**— Obligatoire : numéro (long), pas moins de 1 ou plus de 1000.

Limite le nombre d'enregistrements extraits avec la demande.

- **OrderBy** – Chaîne UTF-8.

Paramètre qui ordonne les données d'aperçu de la réponse.

- **SelectedFields**— Un tableau de chaînes UTF-8, d'au moins 1 ou plus de 1 000 chaînes.

Liste des champs que nous voulons récupérer dans le cadre des données d'aperçu.

Réponse

- **Records** : tableau d'une structure.

Liste des objets demandés.

- NextToken – Chaîne UTF-8, d'une longueur comprise entre 1 et 2048 octets, correspondant au [Custom string pattern #11](#).

Un jeton de continuation, présent si le segment en cours n'est pas le dernier.

Erreurs

- EntityNotFoundException
- OperationTimeoutException
- InvalidInputException
- GlueEncryptionException
- ValidationException
- FederationSourceException
- AccessDeniedException

API de fonction définie par l'utilisateur

L'API des fonctions définies par l'utilisateur décrit les types de AWS Glue données et les opérations utilisés lors de l'utilisation des fonctions.

Types de données

- [UserDefinedFunction structure](#)
- [UserDefinedFunctionInput structure](#)

UserDefinedFunction structure

Représente l'équivalent d'une définition de fonction Hive définie par l'utilisateur (UDF).

Champs

- FunctionName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la fonction.

- DatabaseName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue qui contient la fonction.

- `ClassName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Classe Java qui contient le code de fonction.

- `OwnerName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Propriétaire de la fonction.

- `OwnerType` – Chaîne UTF-8 (valeurs valides : USER | ROLE | GROUP).

Type de propriétaire.

- `CreateTime` – Horodatage.

Heure à laquelle la fonction a été créée.

- `ResourceUris` – Un tableau d'objets [ResourceUri](#), 1000 structures maximum.

La ressource URIs associée à la fonction.

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la fonction.

UserDefinedFunctionInput structure

Structure utilisée pour créer ou mettre à jour une fonction définie par l'utilisateur.

Champs

- `FunctionName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la fonction.

- `ClassName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Classe Java qui contient le code de fonction.

- **OwnerName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Propriétaire de la fonction.

- **OwnerType** – Chaîne UTF-8 (valeurs valides : USER | ROLE | GROUP).

Type de propriétaire.

- **ResourceUris** – Un tableau d'objets [ResourceUri](#), 1000 structures maximum.

La ressource URIs associée à la fonction.

Opérations

- [CreateUserDefinedFunction action \(Python : create_user_defined_function\)](#)
- [UpdateUserDefinedFunction action \(Python : update_user_defined_function\)](#)
- [DeleteUserDefinedFunction action \(Python : delete_user_defined_function\)](#)
- [GetUserDefinedFunction action \(Python : get_user_defined_function\)](#)
- [GetUserDefinedFunctions action \(Python : get_user_defined_functions\)](#)

CreateUserDefinedFunction action (Python : create_user_defined_function)

Crée une nouvelle définition de fonction dans le catalogue de données.

Demande

- **CatalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel créer la fonction. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue dans laquelle créer la fonction.

- **FunctionInput** – Obligatoire : un objet [UserDefinedFunctionInput](#).

Objet **FunctionInput** qui définit la fonction à créer dans le catalogue de données.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `AlreadyExistsException`
- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `GlueEncryptionException`

UpdateUserDefinedFunction action (Python : `update_user_defined_function`)

Met à jour une définition de fonction existante dans le catalogue de données.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données contenant la fonction à mettre à jour. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue contenant la fonction à mettre à jour.

- `FunctionName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la fonction.

- `FunctionInput` – Obligatoire : un objet [UserDefinedFunctionInput](#).

Objet `FunctionInput` qui redéfinit la fonction à créer dans le catalogue de données.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

DeleteUserDefinedFunction action (Python : `delete_user_defined_function`)

Supprime une définition de fonction existante du catalogue de données.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données contenant la fonction à supprimer. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue contenant la fonction.

- `FunctionName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de fonction à supprimer.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- EntityNotFoundException
- InvalidInputException
- InternalServiceException
- OperationTimeoutException

GetUserDefinedFunction action (Python : `get_user_defined_function`)

Extrait une définition de fonction spécifiée du catalogue de données.

Demande

- CatalogId – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données contenant la fonction à extraire. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- DatabaseName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue contenant la fonction.

- FunctionName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la fonction.

Réponse

- UserDefinedFunction – Un objet [UserDefinedFunction](#).

Définition de la fonction demandée.

Erreurs

- EntityNotFoundException
- InvalidInputException

- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

GetUserDefinedFunctions action (Python : `get_user_defined_functions`)

Extrait plusieurs définitions de fonction du catalogue de données.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données contenant les fonction à extraire. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `DatabaseName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue contenant les fonctions. Si aucune n'est fournie, des fonctions de toutes les bases de données du catalogue seront renvoyées.

- `Pattern` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaîne de modèle nom-fonction facultative qui filtre les définitions de fonction renvoyées.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

- `MaxResults` – Nombre (entier), compris entre 1 et 100.

Nombre maximum de fonctions renvoyées par réponse.

Réponse

- `UserDefinedFunctions` – Un tableau d'objets [UserDefinedFunction](#).

Liste des définitions de fonction demandées.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, si la liste de fonctions renvoyée n'inclut pas la dernière fonction demandée.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`

Importation d'un Athena catalogue dans AWS Glue

L'API de migration décrit AWS Glue les types de données et les opérations liées à la migration d'un catalogue de Athena données vers AWS Glue.

Types de données

- [CatalogImportStatus structure](#)

CatalogImportStatus structure

Structure contenant les informations sur le statut de la migration.

Champs

- `ImportCompleted` – Booléen.

True si la migration est terminée ou False dans le cas contraire.

- `ImportTime` – Horodatage.

Heure à laquelle la migration a été démarrée.

- `ImportedBy` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la personne ayant lancé la migration.

Opérations

- [ImportCatalogToGlue action \(Python : import_catalog_to_glue\)](#)
- [GetCatalogImportStatus action \(Python : get_catalog_import_status\)](#)

ImportCatalogToGlue action (Python : import_catalog_to_glue)

Importe un catalogue de données Amazon Athena existant dans. AWS Glue

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue à importer. Actuellement, il devrait s'agir de l'identifiant du AWS compte.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `InternalServiceException`
- `OperationTimeoutException`

GetCatalogImportStatus action (Python : get_catalog_import_status)

Extrait le statut d'une opération de migration.

Demande

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue à migrer. Actuellement, il devrait s'agir de l'identifiant du AWS compte.

Réponse

- `ImportStatus` – Un objet [CatalogImportStatus](#).

Statut de la migration du catalogue spécifié.

Erreurs

- `InternalServiceException`
- `OperationTimeoutException`

API d'optimiseur de table

L'API d'optimisation de table décrit l' AWS Glue API permettant d'activer le compactage afin d'améliorer les performances de lecture.

Types de données

- [TableOptimizer structure](#)
- [TableOptimizerConfiguration structure](#)
- [TableOptimizerVpcConfiguration structure](#)
- [CompactionConfiguration structure](#)
- [IcebergCompactionConfiguration structure](#)
- [TableOptimizerRun structure](#)
- [BatchGetTableOptimizerEntry structure](#)
- [BatchTableOptimizer structure](#)
- [BatchGetTableOptimizerError structure](#)
- [RetentionConfiguration structure](#)
- [IcebergRetentionConfiguration structure](#)
- [OrphanFileDeletionConfiguration structure](#)
- [IcebergOrphanFileDeletionConfiguration structure](#)
- [CompactionMetrics structure](#)
- [RetentionMetrics structure](#)

- [OrphanFileDeletionMetrics structure](#)
- [IcebergCompactionMetrics structure](#)
- [IcebergRetentionMetrics structure](#)
- [IcebergOrphanFileDeletionMetrics structure](#)
- [RunMetrics structure](#)

TableOptimizer structure

Contient des détails sur un optimiseur associé à une table.

Champs

- `type` – Chaîne UTF-8 (valeurs valides : `compaction="COMPACTION" | retention="RETENTION" | orphan_file_deletion="ORPHAN_FILE_DELETION"`).

Le type d'optimiseur de table. Les valeurs valides sont :

- `compaction`: pour gérer le compactage avec un optimiseur de table.
- `retention`: pour gérer la conservation des instantanés à l'aide d'un optimiseur de table.
- `orphan_file_deletion`: pour gérer la suppression de fichiers orphelins à l'aide d'un optimiseur de table.
- `configuration` – Un objet [TableOptimizerConfiguration](#).

Un objet `TableOptimizerConfiguration` spécifié lors de la création ou de la mise à jour d'un optimiseur de table.

- `lastRun` – Un objet [TableOptimizerRun](#).

Un objet `TableOptimizerRun` représentant la dernière exécution de l'optimiseur de table.

TableOptimizerConfiguration structure

Contient des détails sur la configuration d'un optimiseur de table. Vous transmettez cette configuration lors de la création ou de la mise à jour d'un optimiseur de table.

Champs

- `roleArn` – chaîne UTF-8, d'une longueur comprise entre 20 et 2048 octets, correspondant au [Single-line string pattern](#).

Un rôle transmis par l'appelant qui autorise le service à mettre à jour les ressources associées à l'optimiseur au nom de l'appelant.

- `enabled` – Booléen.

Si l'optimisation des tables est activée.

- `vpcConfiguration` – Un objet [TableOptimizerVpcConfiguration](#).

Un `TableOptimizerVpcConfiguration` objet représentant la configuration VPC d'un optimiseur de table.

Cette configuration est nécessaire pour effectuer l'optimisation des tables qui se trouvent dans un VPC client.

- `compactionConfiguration` – Un objet [CompactionConfiguration](#).

Configuration d'un optimiseur de compactage. Cette configuration définit la manière dont les fichiers de données de votre table seront compactés afin d'améliorer les performances des requêtes et de réduire les coûts de stockage.

- `retentionConfiguration` – Un objet [RetentionConfiguration](#).

Configuration d'un optimiseur de conservation des instantanés.

- `orphanFileDeletionConfiguration` – Un objet [OrphanFileDeletionConfiguration](#).

Configuration d'un optimiseur de suppression de fichiers orphelins.

TableOptimizerVpcConfiguration structure

Objet qui décrit la configuration VPC d'un optimiseur de table.

Cette configuration est nécessaire pour effectuer l'optimisation des tables qui se trouvent dans un VPC client.

Champs

- `glueConnectionName` — Chaîne UTF-8, d'une longueur minimale de 1 octet.

Nom de la AWS Glue connexion utilisée pour le VPC pour l'optimiseur de table.

CompactionConfiguration structure

Configuration d'un optimiseur de compactage. Cette configuration définit la manière dont les fichiers de données de votre table seront compactés afin d'améliorer les performances des requêtes et de réduire les coûts de stockage.

Champs

- `icebergConfiguration` – Un objet [IcebergCompactionConfiguration](#).

Configuration d'un optimiseur de compactage Iceberg.

IcebergCompactionConfiguration structure

Configuration d'un optimiseur de compactage Iceberg. Cette configuration définit les paramètres permettant d'optimiser la disposition des fichiers de données dans les tables Iceberg.

Champs

- `strategy` – Chaîne UTF-8 (valeurs valides : `binpack="BINPACK" | sort="SORT" | z-order="ZORDER"`).

La stratégie à utiliser pour le compactage. Les valeurs valides sont :

- `binpack`: combine de petits fichiers en fichiers plus volumineux, en ciblant généralement des tailles supérieures à 100 Mo, tout en appliquant les suppressions en attente. Il s'agit de la stratégie de compactage recommandée pour la plupart des cas d'utilisation.
- `sort`: organise les données en fonction de colonnes spécifiées qui sont triées hiérarchiquement lors du compactage, améliorant ainsi les performances des requêtes pour les opérations filtrées. Cette stratégie est recommandée lorsque vos requêtes filtrent fréquemment sur des colonnes spécifiques. Pour utiliser cette stratégie, vous devez d'abord définir un ordre de tri dans les propriétés de votre table Iceberg à l'aide de la propriété `sort_order` table.
- `z-order`: Optimise l'organisation des données en fusionnant plusieurs attributs en une seule valeur scalaire qui peut être utilisée pour le tri, ce qui permet d'effectuer des requêtes efficaces sur plusieurs dimensions. Cette stratégie est recommandée lorsque vous devez interroger des données sur plusieurs dimensions simultanément. Pour utiliser cette stratégie, vous devez d'abord définir un ordre de tri dans les propriétés de votre table Iceberg à l'aide de la propriété `sort_order` table.

Si aucune entrée n'est fournie, la valeur par défaut « binpack » sera utilisée.

TableOptimizerRun structure

Contient les détails relatifs à l'exécution d'un optimiseur de table.

Champs

- `eventType` – Chaîne UTF-8 (valeurs valides : `starting="STARTING"` | `completed="COMPLETED"` | `failed="FAILED"` | `in_progress="IN_PROGRESS"`).

Un type d'événement représentant l'état de l'exécution de l'optimiseur de table.

- `startTimestamp` – Horodatage.

Représente l'horodatage de l'époque à laquelle la tâche de compactage a commencé dans Lake Formation.

- `endTimestamp` – Horodatage.

Représente l'horodatage de l'époque à laquelle la tâche de compactage s'est terminée.

- `metrics` – Un objet [RunMetrics](#).

Un objet `RunMetrics` contenant des métriques pour l'exécution de l'optimiseur.

Ce membre est obsolète. Consultez les membres individuels de la métrique pour le compactage, la rétention et la suppression des fichiers orphelins.

- `error` – Chaîne UTF-8.

Une erreur survenue lors de l'exécution de l'optimiseur.

- `compactionMetrics` – Un objet [CompactionMetrics](#).

Un objet `CompactionMetrics` contenant des métriques pour l'exécution de l'optimiseur.

- `compactionStrategy` – Chaîne UTF-8 (valeurs valides : `binpack="BINPACK"` | `sort="SORT"` | `z-order="ZORDER"`).

Stratégie utilisée pour le cycle de compactage. Indique quel algorithme a été appliqué pour déterminer comment les fichiers ont été sélectionnés et combinés pendant le processus de compactage. Les valeurs valides sont :

- **binpack**: combine de petits fichiers en fichiers plus volumineux, en ciblant généralement des tailles supérieures à 100 Mo, tout en appliquant les suppressions en attente. Il s'agit de la stratégie de compactage recommandée pour la plupart des cas d'utilisation.
- **sort**: organise les données en fonction de colonnes spécifiées qui sont triées hiérarchiquement lors du compactage, améliorant ainsi les performances des requêtes pour les opérations filtrées. Cette stratégie est recommandée lorsque vos requêtes filtrent fréquemment sur des colonnes spécifiques. Pour utiliser cette stratégie, vous devez d'abord définir un ordre de tri dans les propriétés de votre table Iceberg à l'aide de la propriété `sort_order` table.
- **z-order**: Optimise l'organisation des données en fusionnant plusieurs attributs en une seule valeur scalaire qui peut être utilisée pour le tri, ce qui permet d'effectuer des requêtes efficaces sur plusieurs dimensions. Cette stratégie est recommandée lorsque vous devez interroger des données sur plusieurs dimensions simultanément. Pour utiliser cette stratégie, vous devez d'abord définir un ordre de tri dans les propriétés de votre table Iceberg à l'aide de la propriété `sort_order` table.
- **retentionMetrics** – Un objet [RetentionMetrics](#).

Un objet `RetentionMetrics` contenant des métriques pour l'exécution de l'optimiseur.

- **orphanFileDeletionMetrics** – Un objet [OrphanFileDeletionMetrics](#).

Un `OrphanFileDeletionMetrics` objet contenant des métriques pour l'exécution de l'optimiseur.

BatchGetTableOptimizerEntry structure

Représente un optimiseur de table à récupérer lors de l'opération `BatchGetTableOptimizer`.

Champs

- **catalogId** – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de catalogue de la table.

- **databaseName** — Chaîne UTF-8, d'une longueur minimale de 1 octet.

Nom de la base de données du catalogue où se trouve la table.

- **tableName** — Chaîne UTF-8, d'une longueur minimale de 1 octet.

Nom de la table.

- `type` – Chaîne UTF-8 (valeurs valides : `compaction="COMPACTION" | retention="RETENTION" | orphan_file_deletion="ORPHAN_FILE_DELETION"`).

Le type d'optimiseur de table.

BatchTableOptimizer structure

Contient les détails de l'un des optimiseurs de table renvoyés par l'opération `BatchGetTableOptimizer`.

Champs

- `catalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de catalogue de la table.

- `databaseName` — Chaîne UTF-8, d'une longueur minimale de 1 octet.

Nom de la base de données du catalogue où se trouve la table.

- `tableName` — Chaîne UTF-8, d'une longueur minimale de 1 octet.

Nom de la table.

- `tableOptimizer` – Un objet [TableOptimizer](#).

Un objet `TableOptimizer` qui contient des détails sur la configuration et la dernière exécution d'un optimiseur de table.

BatchGetTableOptimizerError structure

Contient des détails sur l'une des erreurs de la liste d'erreurs renvoyée par l'opération `BatchGetTableOptimizer`.

Champs

- `error` – Un objet [ErrorDetail](#).

Un objet `ErrorDetail` contenant le code et les détails du message sur l'erreur.

- `catalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de catalogue de la table.

- `databaseName` — Chaîne UTF-8, d'une longueur minimale de 1 octet.

Nom de la base de données du catalogue où se trouve la table.

- `tableName` — Chaîne UTF-8, d'une longueur minimale de 1 octet.

Nom de la table.

- `type` – Chaîne UTF-8 (valeurs valides : `compaction="COMPACTION" | retention="RETENTION" | orphan_file_deletion="ORPHAN_FILE_DELETION"`).

Le type d'optimiseur de table.

RetentionConfiguration structure

Configuration d'un optimiseur de conservation des instantanés.

Champs

- `icebergConfiguration` – Un objet [IcebergRetentionConfiguration](#).

Configuration d'un optimiseur de conservation des instantanés Iceberg.

IcebergRetentionConfiguration structure

Configuration d'un optimiseur de conservation des instantanés Iceberg.

Champs

- `snapshotRetentionPeriodInDays` – Nombre (entier).

Le nombre de jours nécessaires pour conserver les instantanés de l'iceberg. Si aucune entrée n'est fournie, le champ de configuration de la table Iceberg correspondant sera utilisé ou, s'il n'est pas présent, la valeur par défaut 5 sera utilisée.

- `numberOfSnapshotsToRetain` – Nombre (entier).

Le nombre de clichés Iceberg à conserver pendant la période de conservation. Si aucune entrée n'est fournie, le champ de configuration de la table Iceberg correspondant sera utilisé ou, s'il n'est pas présent, la valeur par défaut 1 sera utilisée.

- `cleanExpiredFiles` – Booléen.

Si cette valeur est définie sur `false`, les instantanés sont uniquement supprimés des métadonnées de la table, et les fichiers de données et de métadonnées sous-jacents ne sont pas supprimés.

OrphanFileDeletionConfiguration structure

Configuration d'un optimiseur de suppression de fichiers orphelins.

Champs

- `icebergConfiguration` – Un objet [IcebergOrphanFileDeletionConfiguration](#).

Configuration d'un optimiseur de suppression de fichiers orphelins Iceberg.

IcebergOrphanFileDeletionConfiguration structure

Configuration d'un optimiseur de suppression de fichiers orphelins Iceberg.

Champs

- `orphanFileRetentionPeriodInDays` – Nombre (entier).

Nombre de jours pendant lesquels les fichiers orphelins doivent être conservés avant leur suppression. Si aucune entrée n'est fournie, la valeur par défaut 3 sera utilisée.

- `location` – Chaîne UTF-8.

Spécifie un répertoire dans lequel rechercher les fichiers (par défaut, l'emplacement de la table). Vous pouvez choisir un sous-répertoire plutôt que l'emplacement de la table de niveau supérieur.

CompactionMetrics structure

Structure contenant des mesures de compactage pour l'exécution de l'optimiseur.

Champs

- IcebergMetrics – Un objet [IcebergCompactionMetrics](#).

Structure contenant les métriques de compactage d'Iceberg pour l'exécution de l'optimiseur.

RetentionMetrics structure

Structure contenant des mesures de rétention pour l'exécution de l'optimiseur.

Champs

- IcebergMetrics – Un objet [IcebergRetentionMetrics](#).

Structure contenant les métriques de rétention d'Iceberg pour l'exécution de l'optimiseur.

OrphanFileDeletionMetrics structure

Structure contenant des mesures de suppression de fichiers orphelins pour l'exécution de l'optimiseur.

Champs

- IcebergMetrics – Un objet [IcebergOrphanFileDeletionMetrics](#).

Structure contenant les métriques de suppression des fichiers orphelins d'Iceberg pour l'exécution de l'optimiseur.

IcebergCompactionMetrics structure

Mesures de compactage pour Iceberg lors de l'exécution de l'optimiseur.

Champs

- DpuHours – Nombre (double).

Nombre d'heures DPU consommées par la tâche.

- NumberOfDpus— Numéro (entier).

Le nombre de personnes DPUs consommées par la tâche, arrondi au nombre entier le plus proche.

- `JobDurationInHour` – Nombre (double).

Durée de la tâche en heures.

IcebergRetentionMetrics structure

Mesures de rétention des instantanés pour Iceberg lors de l'exécution de l'optimiseur.

Champs

- `DpuHours` – Nombre (double).

Nombre d'heures DPU consommées par la tâche.

- `NumberOfDpus`— Numéro (entier).

Le nombre de personnes DPU consommées par la tâche, arrondi au nombre entier le plus proche.

- `JobDurationInHour` – Nombre (double).

Durée de la tâche en heures.

IcebergOrphanFileDeletionMetrics structure

Mesures de suppression de fichiers orphelins pour Iceberg lors de l'exécution de l'optimiseur.

Champs

- `DpuHours` – Nombre (double).

Nombre d'heures DPU consommées par la tâche.

- `NumberOfDpus`— Numéro (entier).

Le nombre de personnes DPU consommées par la tâche, arrondi au nombre entier le plus proche.

- `JobDurationInHour` – Nombre (double).

Durée de la tâche en heures.

RunMetrics structure

Métriques relatives à l'exécution de l'optimiseur.

Cette structure est obsolète. Consultez les membres individuels de la métrique pour le compactage, la rétention et la suppression des fichiers orphelins.

Champs

- `NumberOfBytesCompacted` – Chaîne UTF-8.

Nombre d'octets supprimés lors de l'exécution de la tâche de compactage.

- `NumberOfFilesCompacted` – Chaîne UTF-8.

Nombre de fichiers supprimés lors de l'exécution de la tâche de compactage.

- `NumberOfDpus` – Chaîne UTF-8.

Le nombre de personnes DPU consommées par la tâche, arrondi au nombre entier le plus proche.

- `JobDurationInHour` – Chaîne UTF-8.

Durée de la tâche en heures.

Opérations

- [GetTableOptimizer action \(Python : `get\_table\_optimizer`\)](#)
- [BatchGetTableOptimizer action \(Python : `batch\_get\_table\_optimizer`\)](#)
- [ListTableOptimizerRuns action \(Python : `list\_table\_optimizer\_runs`\)](#)
- [CreateTableOptimizer action \(Python : `create\_table\_optimizer`\)](#)
- [DeleteTableOptimizer action \(Python : `delete\_table\_optimizer`\)](#)
- [UpdateTableOptimizer action \(Python : `update\_table\_optimizer`\)](#)

GetTableOptimizer action (Python : `get_table_optimizer`)

Renvoie la configuration de tous les optimiseurs associés à une table spécifiée.

Demande

- `CatalogId` – Obligatoire : Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de catalogue de la table.

- DatabaseName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table.

- TableName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table.

- Type – Obligatoire : Chaîne UTF-8 (valeurs valides : compaction="COMPACTION" | retention="RETENTION" | orphan_file_deletion="ORPHAN_FILE_DELETION").

Le type d'optimiseur de table.

Réponse

- CatalogId – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de catalogue de la table.

- DatabaseName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table.

- TableName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table.

- TableOptimizer – Un objet [TableOptimizer](#).

L'optimiseur associé à la table spécifiée.

Erreurs

- EntityNotFoundException
- InvalidInputException
- AccessDeniedException
- InternalServiceException

- `ThrottlingException`

BatchGetTableOptimizer action (Python : `batch_get_table_optimizer`)

Renvoie la configuration des optimiseurs de table spécifiés.

Demande

- `Entries` – Obligatoire : Un tableau d'objets [BatchGetTableOptimizerEntry](#).

Liste d'objets `BatchGetTableOptimizerEntry` spécifiant les optimiseurs de table à récupérer.

Réponse

- `TableOptimizers` – Un tableau d'objets [BatchTableOptimizer](#).

Liste d'objets `BatchTableOptimizer`.

- `Failures` – Un tableau d'objets [BatchGetTableOptimizerError](#).

Liste des erreurs liées à l'opération.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `AccessDeniedException`
- `InternalServiceException`
- `ThrottlingException`

ListTableOptimizerRuns action (Python : `list_table_optimizer_runs`)

Répertorie l'historique des exécutions précédentes de l'optimiseur pour une table spécifique.

Demande

- `CatalogId` – Obligatoire : Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de catalogue de la table.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table.

- `Type` – Obligatoire : Chaîne UTF-8 (valeurs valides : `compaction="COMPACTION" | retention="RETENTION" | orphan_file_deletion="ORPHAN_FILE_DELETION"`).

Le type d'optimiseur de table.

- `MaxResults` – Nombre (entier).

Nombre maximal d'exécutions d'optimisation à renvoyer à chaque appel.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- `CatalogId` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de catalogue de la table.

- `DatabaseName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table.

- `TableName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation pour la pagination de la liste renvoyée des exécutions de l'optimiseur, renvoyé si le segment actuel de la liste n'est pas le dernier.

- TableOptimizerRuns – Un tableau d'objets [TableOptimizerRun](#).

Une liste des exécutions d'optimiseur associées à une table.

Erreurs

- EntityNotFoundException
- AccessDeniedException
- InvalidInputException
- ValidationException
- InternalServiceException
- ThrottlingException

CreateTableOptimizer action (Python : create_table_optimizer)

Crée un nouvel optimiseur de table pour une fonction spécifique.

Demande

- CatalogId – Obligatoire : Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de catalogue de la table.

- DatabaseName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table.

- TableName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table.

- Type – Obligatoire : Chaîne UTF-8 (valeurs valides : compaction="COMPACTION" | retention="RETENTION" | orphan_file_deletion="ORPHAN_FILE_DELETION").

Le type d'optimiseur de table.

- TableOptimizerConfiguration – Obligatoire : un objet [TableOptimizerConfiguration](#).

Un objet TableOptimizerConfiguration représentant la configuration d'un optimiseur de table.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- EntityNotFoundException
- ValidationException
- InvalidInputException
- AccessDeniedException
- AlreadyExistsException
- InternalServiceException
- ThrottlingException

DeleteTableOptimizer action (Python : delete_table_optimizer)

Supprime un optimiseur et toutes les métadonnées associées à une table. L'optimisation ne sera plus effectuée sur la table.

Demande

- CatalogId – Obligatoire : Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de catalogue de la table.

- DatabaseName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table.

- **Type** – Obligatoire : Chaîne UTF-8 (valeurs valides : `compaction="COMPACTION" | retention="RETENTION" | orphan_file_deletion="ORPHAN_FILE_DELETION"`).

Le type d'optimiseur de table.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `AccessDeniedException`
- `InternalServiceException`
- `ThrottlingException`

UpdateTableOptimizer action (Python : `update_table_optimizer`)

Met à jour la configuration d'un optimiseur de table existant.

Demande

- **CatalogId** – Obligatoire : Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de catalogue de la table.

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données du catalogue où se trouve la table.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table.

- Type – Obligatoire : Chaîne UTF-8 (valeurs valides : `compaction="COMPACTION" | retention="RETENTION" | orphan_file_deletion="ORPHAN_FILE_DELETION"`).

Le type d'optimiseur de table.

- `TableOptimizerConfiguration` – Obligatoire : un objet [TableOptimizerConfiguration](#).

Un objet `TableOptimizerConfiguration` représentant la configuration d'un optimiseur de table.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `AccessDeniedException`
- `ValidationException`
- `InternalServiceException`
- `ThrottlingException`
- `ConcurrentModificationException`

API de classifieurs et d'crawlers

L'API Crawler and classifiers décrit les types de données du AWS Glue crawler et du classificateur, et inclut l'API permettant de créer, supprimer, mettre à jour et répertorier les crawlers ou les classificateurs.

Rubriques

- [API du classifieur](#)
- [API du crawler](#)
- [API de statistiques de colonne](#)

- [API du planificateur du crawler](#)

API du classifieur

L'API Classifier décrit les types de données du AWS Glue classificateur et inclut l'API permettant de créer, de supprimer, de mettre à jour et de répertorier les classificateurs.

Types de données

- [Structure du classifieur](#)
- [GrokClassifier structure](#)
- [XMLClassifier structure](#)
- [JsonClassifier structure](#)
- [CsvClassifier structure](#)
- [CreateGrokClassifierRequest structure](#)
- [UpdateGrokClassifierRequest structure](#)
- [Créer une structure XMLClassifier de demande](#)
- [Structure de XMLClassifier demande de mise à jour](#)
- [CreateJsonClassifierRequest structure](#)
- [UpdateJsonClassifierRequest structure](#)
- [CreateCsvClassifierRequest structure](#)
- [UpdateCsvClassifierRequest structure](#)

Structure du classifieur

Les classifieurs sont déclenchés durant une tâche d'analyse. Un classifieur vérifie si un fichier donné est dans un format qu'il peut gérer. Si c'est le cas, le classifieur crée un schéma sous la forme d'un objet `StructType` correspondant à ce format de données.

Vous pouvez utiliser les classificateurs standard AWS Glue fournis, ou vous pouvez écrire vos propres classificateurs pour classer au mieux vos sources de données et spécifier les schémas appropriés à utiliser pour celles-ci. Un classifieur peut être un classifieur `grok`, un classifieur XML, un classifieur JSON ou un classifieur CSV personnalisé, selon ce qui est spécifié dans l'un des champs de l'objet `Classifier`.

Champs

- `GrokClassifier` – Un objet [GrokClassifier](#).

Classificateur qui utilise grok.

- `XMLClassifier` – Un objet [XMLClassifier](#).

Classificateur de contenu XML.

- `JsonClassifier` – Un objet [JsonClassifier](#).

Classificateur de contenu JSON.

- `CsvClassifier` – Un objet [CsvClassifier](#).

Classificateur pour les valeurs séparées par des virgules (CSV).

GrokClassifier structure

Classifieur qui utilise des modèles grok.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du classifieur.

- `Classification` – Obligatoire : chaîne UTF-8.

Identifiant du format des données auquel le classifieur correspond, comme les journaux Twitter, JSON, Omniture, etc.

- `CreationTime` – Horodatage.

Heure à laquelle ce classificateur a été enregistré.

- `LastUpdated` – Horodatage.

Heure de la dernière mise à jour de ce classifieur.

- `Version` – Nombre (long).

Version de ce classifieur.

- **GrokPattern** – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 2048 octets, correspondant au [A Logstash Grok string pattern](#).

Modèle grok appliqué à un magasin de données par ce classifieur. Pour plus d'informations, consultez les modèles intégrés dans [Writing Custom Classifiers](#) (Écriture de classifieurs personnalisés).

- **CustomPatterns** – Chaîne UTF-8, d'une longueur maximale de 16 000 octets, correspondant au [URI address multi-line string pattern](#).

Modèles grok personnalisés facultatifs définis par ce classifieur. Pour plus d'informations, consultez les modèles personnalisés dans [Writing Custom Classifiers](#) (Écriture de classifieurs personnalisés).

XMLClassifier structure

Classifieur de contenu XML.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du classifieur.

- **Classification** – Obligatoire : chaîne UTF-8.

Identifiant du format des données que le classifieur fait correspondre.

- **CreationTime** – Horodatage.

Heure à laquelle ce classificateur a été enregistré.

- **LastUpdated** – Horodatage.

Heure de la dernière mise à jour de ce classifieur.

- **Version** – Nombre (long).

Version de ce classifieur.

- **RowTag** – Chaîne UTF-8.

Balise XML désignant l'élément contenant chaque enregistrement d'un document XML en cours d'analyse. Cela ne permet pas d'identifier un élément à fermeture automatique (fermé par />). Un élément de ligne vide contenant uniquement des attributs peut être analysé tant qu'il se termine

par une balise de fermeture (par exemple, `<row item_a="A" item_b="B"></row>` est correct, mais `<row item_a="A" item_b="B" />` ne l'est pas).

JsonClassifier structure

Classifieur de contenu JSON.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du classifieur.

- **CreationTime** – Horodatage.

Heure à laquelle ce classificateur a été enregistré.

- **LastUpdated** – Horodatage.

Heure de la dernière mise à jour de ce classifieur.

- **Version** – Nombre (long).

Version de ce classifieur.

- **JsonPath** – Obligatoire : chaîne UTF-8.

JsonPathChaîne définissant les données JSON à classer par le classificateur. AWS Glue prend en charge un sous-ensemble de JsonPath, comme décrit dans la section [Écrire des JsonPath classificateurs personnalisés](#).

CsvClassifier structure

Classifieur de contenu CSV personnalisé.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du classifieur.

- **CreationTime** – Horodatage.

Heure à laquelle ce classificateur a été enregistré.

- `LastUpdated` – Horodatage.

Heure de la dernière mise à jour de ce classifieur.

- `Version` – Nombre (long).

Version de ce classifieur.

- `Delimiter` – Chaîne UTF-8, d'une longueur d'au moins 1 ou de plus de 1 octet, correspondant au [Custom string pattern #26](#).

Symbole personnalisé pour indiquer ce qui sépare chaque entrée de colonne dans la ligne.

- `QuoteSymbol` – Chaîne UTF-8, d'une longueur d'au moins 1 ou de plus de 1 octet, correspondant au [Custom string pattern #26](#).

Symbole personnalisé pour indiquer ce qui combine le contenu en une seule valeur de colonne. Doit être différent du délimiteur de colonne.

- `ContainsHeader` – Chaîne UTF-8 (valeurs valides : UNKNOWN | PRESENT | ABSENT).

Indique si le fichier CSV contient un en-tête.

- `Header` – Tableau de chaînes UTF-8.

Liste des chaînes représentant les noms des colonnes.

- `DisableValueTrimming` – Booléen.

Spécifie de ne pas couper les valeurs avant d'identifier le type des valeurs de colonne. La valeur par défaut est `true`.

- `AllowSingleColumn` – Booléen.

Active le traitement des fichiers qui ne contiennent qu'une seule colonne.

- `CustomDatatypeConfigured` – Booléen.

Permet de configurer le type de données personnalisé.

- `CustomDatatypes` – Tableau de chaînes UTF-8.

Liste de types de données personnalisés, notamment « BINARY », « BOOLEAN », « DATE », « DECIMAL », « DOUBLE », « FLOAT », « INT », « LONG », « SHORT », « STRING », « TIMESTAMP ».

- **Serde** – Chaîne UTF-8 (valeurs valides : `OpenCSVSerde` | `LazySimpleSerde` | `None`).

Définit le CSV SerDe pour le traitement dans le classificateur, qui sera appliqué dans le catalogue de données. Les valeurs valides sont `OpenCSVSerde`, `LazySimpleSerde` et `None`. Vous pouvez spécifier la valeur `None` lorsque vous souhaitez que le Crawler effectue la détection.

CreateGrokClassifierRequest structure

Spécifie un classifieur grok que `CreateClassifier` doit créer.

Champs

- **Classification** – Obligatoire : chaîne UTF-8.

Identifiant du format de données auquel le classificateur correspond, tel que Twitter, JSON, Omniture CloudWatch logs, Amazon Logs, etc.

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du nouveau classifieur.

- **GrokPattern** – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 2048 octets, correspondant au [A Logstash Grok string pattern](#).

Modèle grok utilisé par ce classifieur.

- **CustomPatterns** – Chaîne UTF-8, d'une longueur maximale de 16 000 octets, correspondant au [URI address multi-line string pattern](#).

Modèles grok personnalisés facultatifs utilisés par ce classifieur.

UpdateGrokClassifierRequest structure

Spécifie un classifieur grok à mettre à jour lorsqu'il est transmis à `UpdateClassifier`.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de l'`GrokClassifier`.

- **Classification** – Chaîne UTF-8.

Identifiant du format de données auquel le classificateur correspond, tel que Twitter, JSON, Omniture CloudWatch logs, Amazon Logs, etc.

- **GrokPattern** – Chaîne UTF-8, d'une longueur comprise entre 1 et 2048 octets, correspondant au [A Logstash Grok string pattern](#).

Modèle grok utilisé par ce classifieur.

- **CustomPatterns** – Chaîne UTF-8, d'une longueur maximale de 16 000 octets, correspondant au [URI address multi-line string pattern](#).

Modèles grok personnalisés facultatifs utilisés par ce classifieur.

Créer une structure XMLClassifier de demande

Spécifie un classifieur XML que `CreateClassifier` doit créer.

Champs

- **Classification** – Obligatoire : chaîne UTF-8.

Identifiant du format des données que le classifieur fait correspondre.

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du classifieur.

- **RowTag** – Chaîne UTF-8.

Balise XML désignant l'élément contenant chaque enregistrement d'un document XML en cours d'analyse. Cela ne permet pas d'identifier un élément à fermeture automatique (fermé par `</>`). Un élément de ligne vide contenant uniquement des attributs peut être analysé tant qu'il se termine par une balise de fermeture (par exemple, `<row item_a="A" item_b="B"></row>` est correct, mais `<row item_a="A" item_b="B" />` ne l'est pas).

Structure de XMLClassifier demande de mise à jour

Spécifie un classifieur XML à mettre à jour.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du classifieur.

- **Classification** – Chaîne UTF-8.

Identifiant du format des données que le classifieur fait correspondre.

- **RowTag** – Chaîne UTF-8.

Balise XML désignant l'élément contenant chaque enregistrement d'un document XML en cours d'analyse. Cela ne permet pas d'identifier un élément à fermeture automatique (fermé par `</>`). Un élément de ligne vide contenant uniquement des attributs peut être analysé tant qu'il se termine par une balise de fermeture (par exemple, `<row item_a="A" item_b="B"></row>` est correct, mais `<row item_a="A" item_b="B" />` ne l'est pas).

CreateJsonClassifierRequest structure

Spécifie un classifieur JSON que CreateClassifier doit créer.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du classifieur.

- **JsonPath** – Obligatoire : chaîne UTF-8.

JsonPathChaîne définissant les données JSON à classer par le classificateur. AWS Glue prend en charge un sous-ensemble de JsonPath, comme décrit dans la section [Écrire des JsonPath classificateurs personnalisés](#).

UpdateJsonClassifierRequest structure

Spécifie un classifieur JSON à mettre à jour.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du classifieur.

- **JsonPath** – Chaîne UTF-8.

JsonPath Chaîne définissant les données JSON à classer par le classificateur. AWS Glue prend en charge un sous-ensemble de JsonPath, comme décrit dans la section [Écrire des JsonPath classificateurs personnalisés](#).

CreateCsvClassifierRequest structure

Spécifie un classifieur CSV personnalisé que CreateClassifier doit créer.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du classifieur.

- **Delimiter** – Chaîne UTF-8, d'une longueur d'au moins 1 ou de plus de 1 octet, correspondant au [Custom string pattern #26](#).

Symbole personnalisé pour indiquer ce qui sépare chaque entrée de colonne dans la ligne.

- **QuoteSymbol** – Chaîne UTF-8, d'une longueur d'au moins 1 ou de plus de 1 octet, correspondant au [Custom string pattern #26](#).

Symbole personnalisé pour indiquer ce qui combine le contenu en une seule valeur de colonne. Doit être différent du délimiteur de colonne.

- **ContainsHeader** – Chaîne UTF-8 (valeurs valides : UNKNOWN | PRESENT | ABSENT).

Indique si le fichier CSV contient un en-tête.

- **Header** – Tableau de chaînes UTF-8.

Liste des chaînes représentant les noms des colonnes.

- **DisableValueTrimming** – Booléen.

Spécifie de ne pas couper les valeurs avant d'identifier le type des valeurs de colonne. La valeur par défaut est True.

- `AllowSingleColumn` – Booléen.

Active le traitement des fichiers qui ne contiennent qu'une seule colonne.

- `CustomDatatypeConfigured` – Booléen.

Permet la configuration du type de données personnalisé.

- `CustomDatatypes` – Tableau de chaînes UTF-8.

Crée une liste des types de données personnalisés pris en charge.

- `Serde` – Chaîne UTF-8 (valeurs valides : `OpenCSVSerde` | `LazySimpleSerde` | `None`).

Définit le CSV SerDe pour le traitement dans le classificateur, qui sera appliqué dans le catalogue de données. Les valeurs valides sont `OpenCSVSerde`, `LazySimpleSerde` et `None`. Vous pouvez spécifier la valeur `None` lorsque vous souhaitez que le Crawler effectue la détection.

UpdateCsvClassifierRequest structure

Spécifie un classifieur CSV personnalisé à mettre à jour.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du classifieur.

- `Delimiter` – Chaîne UTF-8, d'une longueur d'au moins 1 ou de plus de 1 octet, correspondant au [Custom string pattern #26](#).

Symbole personnalisé pour indiquer ce qui sépare chaque entrée de colonne dans la ligne.

- `QuoteSymbol` – Chaîne UTF-8, d'une longueur d'au moins 1 ou de plus de 1 octet, correspondant au [Custom string pattern #26](#).

Symbole personnalisé pour indiquer ce qui combine le contenu en une seule valeur de colonne. Doit être différent du délimiteur de colonne.

- `ContainsHeader` – Chaîne UTF-8 (valeurs valides : `UNKNOWN` | `PRESENT` | `ABSENT`).

Indique si le fichier CSV contient un en-tête.

- `Header` – Tableau de chaînes UTF-8.

Liste des chaînes représentant les noms des colonnes.

- `DisableValueTrimming` – Booléen.

Spécifie de ne pas couper les valeurs avant d'identifier le type des valeurs de colonne. La valeur par défaut est `True`.

- `AllowSingleColumn` – Booléen.

Active le traitement des fichiers qui ne contiennent qu'une seule colonne.

- `CustomDatatypeConfigured` – Booléen.

Spécifie la configuration du type de données personnalisé.

- `CustomDatatypes` – Tableau de chaînes UTF-8.

Spécifie une liste des types de données personnalisés pris en charge.

- `Serde` – Chaîne UTF-8 (valeurs valides : `OpenCSVSerde` | `LazySimpleSerde` | `None`).

Définit le CSV SerDe pour le traitement dans le classificateur, qui sera appliqué dans le catalogue de données. Les valeurs valides sont `OpenCSVSerde`, `LazySimpleSerde` et `None`. Vous pouvez spécifier la valeur `None` lorsque vous souhaitez que le Crawler effectue la détection.

Opérations

- [CreateClassifier action \(Python : `create\_classifier`\)](#)
- [DeleteClassifier action \(Python : `delete\_classifier`\)](#)
- [GetClassifier action \(Python : `get\_classifier`\)](#)
- [GetClassifiers action \(Python : `get\_classifiers`\)](#)
- [UpdateClassifier action \(Python : `update\_classifier`\)](#)

CreateClassifier action (Python : `create_classifier`)

Crée un classifieur dans le compte de l'utilisateur. Cela peut être un `GrokClassifier`, un `XMLClassifier`, un `JsonClassifier` ou un `CsvClassifier`, selon le champ de la demande qui est présent.

Demande

- GrokClassifier – Un objet [CreateGrokClassifierRequest](#).

Un GrokClassifier objet spécifiant le classifieur à créer.

- XMLClassifier – Un objet [Créer une XMLClassifier demande](#).

Un XMLClassifier objet spécifiant le classifieur à créer.

- JsonClassifier – Un objet [CreateJsonClassifierRequest](#).

Un JsonClassifier objet spécifiant le classifieur à créer.

- CsvClassifier – Un objet [CreateCsvClassifierRequest](#).

Un CsvClassifier objet spécifiant le classifieur à créer.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- AlreadyExistsException
- InvalidInputException
- OperationTimeoutException

DeleteClassifier action (Python : delete_classifier)

Supprime un classifieur du catalogue de données.

Demande

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du classifieur à supprimer.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `OperationTimeoutException`

GetClassifier action (Python : `get_classifier`)

Récupérer un classifieur par son nom.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du classifieur à récupérer.

Réponse

- **Classifier** – Un objet [Classifieur](#).

Classifieur demandé.

Erreurs

- `EntityNotFoundException`
- `OperationTimeoutException`

GetClassifiers action (Python : `get_classifiers`)

Répertorie toutes les objets Classifieur du catalogue de données.

Demande

- **MaxResults** – Nombre (entier), compris entre 1 et 1 000.

Taille de la liste à renvoyer (facultatif).

- NextToken – Chaîne UTF-8.

Jeton de continuation facultatif.

Réponse

- Classifiers – Un tableau d'objets [Classifieur](#).

Liste des objets Classifier demandée.

- NextToken – Chaîne UTF-8.

Jeton de continuation.

Erreurs

- OperationTimeoutException

UpdateClassifier action (Python : update_classifier)

Modifie un classifieur existant (GrokClassifier, XMLClassifier, JsonClassifier ou CsvClassifier, selon le champ qui est présent).

Demande

- GrokClassifier – Un objet [UpdateGrokClassifierRequest](#).

Un objet GrokClassifier avec des champs mis à jour.

- XMLClassifier – Un objet [XMLClassifierDemande de mise à jour](#).

Un objet XMLClassifier avec des champs mis à jour.

- JsonClassifier – Un objet [UpdateJsonClassifierRequest](#).

Un objet JsonClassifier avec des champs mis à jour.

- CsvClassifier – Un objet [UpdateCsvClassifierRequest](#).

Un objet CsvClassifier avec des champs mis à jour.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `InvalidInputException`
- `VersionMismatchException`
- `EntityNotFoundException`
- `OperationTimeoutException`

API du crawler

L'API Crawler décrit les types de données des AWS Glue robots d'exploration, ainsi que l'API permettant de créer, de supprimer, de mettre à jour et de répertorier les robots d'exploration.

Types de données

- [Structure du crawler](#)
- [Structure du planificateur](#)
- [CrawlerTargets structure](#)
- [Structure de la S3Target](#)
- [DeltaCatalogTarget Structure S3](#)
- [DeltaDirectTarget Structure S3](#)
- [JdbcTarget structure](#)
- [Structure Mongo DBTarget](#)
- [Structure de la dynamo DBTarget](#)
- [DeltaTarget structure](#)
- [IcebergTarget structure](#)
- [HudiTarget structure](#)
- [CatalogTarget structure](#)
- [CrawlerMetrics structure](#)
- [CrawlerHistory structure](#)

- [CrawlsFilter structure](#)
- [SchemaChangePolicy structure](#)
- [LastCrawlInfo structure](#)
- [RecrawlPolicy structure](#)
- [LineageConfiguration structure](#)
- [LakeFormationConfiguration structure](#)

Structure du crawler

Spécifie un crawler qui examine une source de données et utilise des classifieurs pour tenter de déterminer son schéma. Si l'action aboutit, l'crawler enregistre les métadonnées relatives à la source de données dans le AWS Glue Data Catalog.

Champs

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'crawler.

- **Role** – Chaîne UTF-8.

L'Amazon Resource Name (ARN) d'un rôle IAM utilisé pour accéder aux ressources client, par exemple des données Amazon Simple Storage Service (Amazon S3).

- **Targets** – Un objet [CrawlerTargets](#).

Ensemble de cibles à analyser.

- **DatabaseName** – Chaîne UTF-8.

Nom de la base de données dans laquelle le résultat de l'crawler est stockée.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du crawler.

- **Classifiers** – Tableau de chaînes UTF-8.

Liste de chaînes UTF-8 qui spécifient les classificateurs personnalisés et associés à l'crawler.

- **RecrawlPolicy** – Un objet [RecrawlPolicy](#).

Stratégie qui spécifie s'il faut analyser à nouveau le jeu de données entier ou analyser uniquement les dossiers ajoutés depuis la dernière exécution du crawler.

- `SchemaChangePolicy` – Un objet [SchemaChangePolicy](#).

Stratégie qui spécifie la mise à jour et la suppression des comportements pour l'crawler.

- `LineageConfiguration` – Un objet [LineageConfiguration](#).

Configuration qui spécifie si la lignée de données est activée pour le crawler.

- `State` – Chaîne UTF-8 (valeurs valides : READY | RUNNING | STOPPING).

Indique si le crawler est en cours d'exécution, ou si une exécution est en attente.

- `TablePrefix` – Chaîne UTF-8, d'une longueur maximale de 128 octets.

Préfixe ajouté aux noms des tables créées.

- `Schedule` – Un objet [Planificateur](#).

Pour les crawlers planifiés, planification de l'exécution du crawler.

- `CrawlElapsedTime` – Nombre (long).

Si le crawler est en cours d'exécution, contient le temps écoulé total depuis le début de la dernière analyse.

- `CreationTime` – Horodatage.

Heure de création du crawler.

- `LastUpdated` – Horodatage.

Heure de la dernière mise à jour du crawler.

- `LastCrawl` – Un objet [LastCrawlInfo](#).

État de la dernière analyse, et éventuellement informations d'erreur si une erreur s'est produite.

- `Version` – Nombre (long).

Version de l'crawler.

- `Configuration` – Chaîne UTF-8.

Informations sur la configuration du crawler. Cette chaîne JSON avec gestion des versions permet aux utilisateurs de spécifier des aspects du comportement d'un crawler. Pour plus d'informations, consultez [Setting Crawler configuration options](#) (Définition d'options de configuration du crawler).

- `CrawlerSecurityConfiguration` – Chaîne UTF-8, d'une longueur maximale de 128 octets.

Nom de la structure `SecurityConfiguration` qui sera utilisée par ce crawler.

- `LakeFormationConfiguration` – Un objet [LakeFormationConfiguration](#).

Spécifie si le robot d'exploration doit utiliser les AWS Lake Formation informations d'identification du robot au lieu des informations d'identification du rôle IAM.

Structure du planificateur

Objet de planification utilisant une instruction `cron` pour planifier un événement.

Champs

- `ScheduleExpression` – Chaîne UTF-8.

Une expression `cron` utilisée pour spécifier la planification (consultez [Time-Based Schedules for Jobs and Crawlers](#) (Planifications temporelles pour les tâches et les crawlers)). Par exemple, pour exécuter un élément tous les jours à 12h15 UTC, vous devez spécifier : `cron(15 12 * * ? *)`.

- `State` – Chaîne UTF-8 (valeurs valides : `SCHEDULED` | `NOT_SCHEDULED` | `TRANSITIONING`).

État de la planification.

CrawlerTargets structure

Indique les magasins de données à analyser.

Champs

- `S3Targets` – Un tableau d'objets [S3Target](#).

Spécifie des cibles Amazon Simple Storage Service (Amazon S3).

- `JdbcTargets` – Un tableau d'objets [JdbcTarget](#).

Spécifie les cibles JDBC.

- **MongoDBTargets** – Un tableau d'objets [Mongo DBTarget](#).

Spécifie les cibles Amazon DocumentDB ou MongoDB.

- **DynamoDBTargets** – Un tableau d'objets [Dynamo DBTarget](#).

Spécifie des cibles Amazon DynamoDB.

- **CatalogTargets** – Un tableau d'objets [CatalogTarget](#).

Spécifie AWS Glue Data Catalog les cibles.

- **DeltaTargets** – Un tableau d'objets [DeltaTarget](#).

Spécifie les cibles du stockage de données Delta.

- **IcebergTargets** – Un tableau d'objets [IcebergTarget](#).

Spécifie les cibles du magasin de données Apache Iceberg.

- **HudiTargets** – Un tableau d'objets [HudiTarget](#).

Spécifie les cibles du magasin de données Hudi Iceberg.

Structure de la S3Target

Spécifie un magasin de données dans Amazon Simple Storage Service (Amazon S3).

Champs

- **Path** – Chaîne UTF-8.

Chemin vers la cible Amazon S3.

- **Exclusions** – Tableau de chaînes UTF-8.

Liste de modèles glob utilisés à exclure de l'analyse. Pour en savoir plus, consultez [Catalog Tables with a Crawler](#) (Tables de catalogues avec un crawler).

- **ConnectionName**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Nom d'une connexion qui permet à une tâche ou à un crawler d'accéder aux données dans Amazon S3 au sein d'un environnement Amazon Virtual Private Cloud (Amazon VPC).

- **SampleSize** – Nombre (entier).

Définit le nombre de fichiers dans chaque dossier feuille à analyser lors de l'analyse d'échantillons de fichiers dans un jeu de données. Si ce paramètre n'est pas défini, tous les fichiers sont analysés. Une valeur valide est un entier compris entre 1 et 249.

- `EventQueueArn` – Chaîne UTF-8.

Un ARN Amazon SQS valide. Par exemple, `arn:aws:sqs:region:account:sqs`.

- `DlqEventQueueArn` – Chaîne UTF-8.

Un ARN SQS de lettres mortes Amazon valide. Par exemple, `arn:aws:sqs:region:account:deadLetterQueue`.

DeltaCatalogTarget Structure S3

Spécifie une cible qui écrit dans une source de données Delta Lake dans le catalogue de AWS Glue données.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- `Inputs` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- `PartitionKeys` – Tableau de chaînes UTF-8.

Indique le partitionnement natif à l'aide d'une séquence de clés.

- `Table` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table de la base de données dans laquelle écrire les données.

- `Database` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données dans laquelle écrire les données.

- `AdditionalOptions` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique des options de connexion supplémentaires pour le connecteur.

- `SchemaChangePolicy` – Un objet [CatalogSchemaChangePolicy](#).

Une politique qui indique les évolutions de mise à jour pour le crawler.

DeltaDirectTarget Structure S3

Spécifie une cible qui écrit dans une source de données de Delta Lake en Amazon S3.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- `Inputs` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- `PartitionKeys` – Tableau de chaînes UTF-8.

Indique le partitionnement natif à l'aide d'une séquence de clés.

- `Path` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le chemin d'accès Amazon S3 de votre source de données Delta Lake sur laquelle écrire.

- `Compression` – Obligatoire : Chaîne UTF-8 (valeurs valides : `uncompressed="UNCOMPRESSED"` | `snappy="SNAPPY"`).

Indique la manière dont les données sont comprimées. Ce n'est généralement pas nécessaire si le fichier de données a une extension standard. Les valeurs possibles sont `"gzip"` et `"bzip"`.

- `NumberTargetPartitions` – Chaîne UTF-8.

Spécifie le nombre de partitions cibles pour la distribution des fichiers de données Delta Lake sur Amazon S3.

- `Format`— Obligatoire : chaîne UTF-8 (valeurs valides : `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

Définit le format de sortie des données pour la cible.

- `AdditionalOptions` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique des options de connexion supplémentaires pour le connecteur.

- `SchemaChangePolicy` – Un objet [DirectSchemaChangePolicy](#).

Une politique qui indique les évolutions de mise à jour pour le crawler.

JdbcTarget structure

Indique les magasins de données JDBC à analyser.

Champs

- `ConnectionName`— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Nom de la connexion à utiliser pour se connecter à la cible JDBC.

- `Path` – Chaîne UTF-8.

Le chemin de la cible JDBC.

- `Exclusions` – Tableau de chaînes UTF-8.

Liste de modèles glob utilisés à exclure de l'analyse. Pour en savoir plus, consultez [Catalog Tables with a Crawler](#) (Tables de catalogues avec un crawler).

- `EnableAdditionalMetadata` – Tableau de chaînes UTF-8.

Spécifiez une valeur de `RAWTYPES` ou `COMMENTS` pour activer des métadonnées supplémentaires dans les réponses des tables. `RAWTYPES` fournit le type de données de niveau natif. `COMMENTS` fournit des commentaires associés à une colonne ou à une table de la base de données.

Si vous n'avez pas besoin d'autres métadonnées, laissez le champ vide.

Structure Mongo DBTarget

Indique les magasins de données Amazon DocumentDB ou MongoDB à analyser.

Champs

- `ConnectionName`— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Nom de la connexion à utiliser pour se connecter à la cible Amazon DocumentDB ou MongoDB.

- `Path` – Chaîne UTF-8.

Chemin d'accès de la cible Amazon DocumentDB ou MongoDB (base de données/collection).

- `ScanAll` – Booléen.

Indique s'il faut analyser tous les enregistrements ou échantillonner les lignes de la table. L'analyse de tous les enregistrements peut prendre beaucoup de temps lorsque la table n'est pas à haut débit.

La valeur `true` implique l'analyse de tous les enregistrements, tandis que la valeur `false` implique l'échantillonnage des enregistrements. Si aucune valeur n'est spécifiée, la valeur par défaut est `true`.

Structure de la dynamo DBTarget

Spécifie une table Amazon DynamoDB à analyser.

Champs

- `Path` – Chaîne UTF-8.

Nom de la table DynamoDB à analyser.

- `scanAll` – Booléen.

Indique s'il faut analyser tous les enregistrements ou échantillonner les lignes de la table. L'analyse de tous les enregistrements peut prendre beaucoup de temps lorsque la table n'est pas à haut débit.

La valeur `true` implique l'analyse de tous les enregistrements, tandis que la valeur `false` implique l'échantillonnage des enregistrements. Si aucune valeur n'est spécifiée, la valeur par défaut est `true`.

- `scanRate` – Nombre (double).

Pourcentage d'unités de capacité de lecture configurées à utiliser par le AWS Glue robot d'exploration. Unités de capacité de lecture est un terme défini par DynamoDB et est une valeur numérique qui sert de limiteur de vitesse pour le nombre de lectures pouvant être effectuées sur cette table par seconde.

Les valeurs valides sont nulles ou une valeur comprise entre 0,1 et 1,5. Une valeur NULL est utilisée lorsque l'utilisateur ne fournit pas de valeur et que la valeur par défaut est 0,5 de l'unité de capacité de lecture configurée (pour les tables provisionnées) ou 0,25 de l'unité de capacité de lecture maximale configurée (pour les tables utilisant le mode à la demande).

DeltaTarget structure

Spécifie un stockage de données Delta pour analyser un ou plusieurs tableaux Delta.

Champs

- `DeltaTables` – Tableau de chaînes UTF-8.

Une liste de chemins Amazon S3 vers les tableaux Delta.

- `ConnectionName`— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Nom de la connexion à utiliser pour se connecter à la cible Delta.

- `WriteManifest` – Booléen.

Spécifie s'il faut écrire les fichiers manifestes dans le chemin d'accès au tableau Delta.

- `CreateNativeDeltaTable` – Booléen.

Spécifie si le crawler va créer des tables natives pour permettre l'intégration avec les moteurs de requêtes qui prennent directement en charge l'interrogation du journal de transactions Delta.

IcebergTarget structure

Spécifie une source de données Apache Iceberg où les tables Iceberg sont stockées dans Amazon S3.

Champs

- `Paths` – Tableau de chaînes UTF-8.

Un ou plusieurs Amazon S3 chemins contenant les dossiers de métadonnées Iceberg en tant que `s3://bucket/prefix`.

- **ConnectionName**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Nom de la connexion à utiliser pour se connecter à la cible Iceberg.

- **Exclusions** – Tableau de chaînes UTF-8.

Liste de modèles glob utilisés à exclusion de l'analyse. Pour en savoir plus, consultez [Catalog Tables with a Crawler](#) (Tables de catalogues avec un crawler).

- **MaximumTraversalDepth** – Nombre (entier).

Profondeur maximale des Amazon S3 chemins que le robot d'exploration peut parcourir pour découvrir le dossier de métadonnées Iceberg dans votre Amazon S3 chemin. Utilisé pour limiter le temps d'exécution du Crawler.

HudiTarget structure

Spécifie une source de données Apache Hudi.

Champs

- **Paths** – Tableau de chaînes UTF-8.

Tableau de chaînes de Amazon S3 localisation pour Hudi, chacune indiquant le dossier racine dans lequel se trouvent les fichiers de métadonnées d'une table Hudi. Le dossier Hudi peut se trouver dans un dossier enfant du dossier racine.

Le Crawler examine tous les dossiers situés sous un chemin à la recherche d'un dossier Hudi.

- **ConnectionName**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Nom de la connexion à utiliser pour se connecter à la cible Hudi. Si vos fichiers Hudi sont stockés dans des compartiments nécessitant une autorisation VPC, vous pouvez définir leurs propriétés de connexion ici.

- **Exclusions** – Tableau de chaînes UTF-8.

Liste de modèles glob utilisés à exclusion de l'analyse. Pour en savoir plus, consultez [Catalog Tables with a Crawler](#) (Tables de catalogues avec un crawler).

- **MaximumTraversalDepth** – Nombre (entier).

Profondeur maximale des Amazon S3 chemins que le robot d'exploration peut parcourir pour découvrir le dossier de métadonnées Hudi dans votre Amazon S3 chemin. Utilisé pour limiter le temps d'exécution du Crawler.

CatalogTarget structure

Spécifie une AWS Glue Data Catalog cible.

Champs

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la base de données à synchroniser.

- **Tables** – Obligatoire : Tableau de chaînes UTF-8, au moins 1 chaîne.

Une liste des tables à synchroniser.

- **ConnectionName**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Le nom de la connexion d'une table de catalogue de données basées sur Amazon S3 qui doit être la cible de l'analyse lors de l'utilisation d'un type de connexion Catalog associé à un type de connexion NETWORK.

- **EventQueueArn** – Chaîne UTF-8.

Un ARN Amazon SQS valide. Par exemple, `arn:aws:sqs:region:account:sqs`.

- **DLqEventQueueArn** – Chaîne UTF-8.

Un ARN SQS de lettres mortes Amazon valide. Par exemple, `arn:aws:sqs:region:account:deadLetterQueue`.

CrawlerMetrics structure

Métriques d'un crawler spécifié.

Champs

- **CrawlerName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'crawler.

- `TimeLeftSeconds` – Nombre (double), pas plus qu'Aucun.

Estimation du temps restant pour terminer une analyse en cours d'exécution.

- `StillEstimating` – Booléen.

True si le crawler est toujours en cours d'estimation du temps nécessaire pour terminer cette exécution.

- `LastRuntimeSeconds` – Nombre (double), pas plus qu'Aucun.

Durée de l'exécution la plus récente de l'crawler, en secondes.

- `MedianRuntimeSeconds` – Nombre (double), pas plus qu'Aucun.

Durée médiane des exécutions de cet crawler, en secondes.

- `TablesCreated` – Nombre (entier), pas plus qu'Aucun.

Nombre de tables créées par cet crawler.

- `TablesUpdated` – Nombre (entier), pas plus qu'Aucun.

Nombre de tables mises à jour par cet crawler.

- `TablesDeleted` – Nombre (entier), pas plus qu'Aucun.

Nombre de tables supprimées par cet crawler.

CrawlerHistory structure

Contient les informations pour une exécution d'un crawler.

Champs

- `CrawlId` – Chaîne UTF-8.

Un identifiant UUID pour chaque analyse.

- `State` – Chaîne UTF-8 (valeurs valides : `RUNNING` | `COMPLETED` | `FAILED` | `STOPPED`).

État de l'analyse.

- `StartTime` – Horodatage.

Date et heure auxquelles le crawler a démarré.

- EndTime – Horodatage.

Date et heure auxquelles l'analyse s'est achevée.

- Summary – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Un résumé d'exécution pour l'analyse spécifique dans JSON. Contient les tables de catalogue et les partitions qui ont été ajoutées, mises à jour ou supprimées.

- ErrorMessage – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Si une erreur s'est produite, le message d'erreur associé à l'analyse.

- LogGroup – Chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets, correspondant au [Log group string pattern](#).

Groupe de journaux associés au crawler.

- LogStream – Chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets, correspondant au [Log-stream string pattern](#).

Flux de journaux associé au crawler.

- MessagePrefix – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le préfixe d'un CloudWatch message concernant ce crawl.

- DPUHour – Nombre (double), pas plus qu'Aucun.

Nombre d'unités de traitement de données (DPU) utilisées en heures pour l'analyse.

CrawlsFilter structure

Une liste de champs, de comparateurs et de valeurs que vous pouvez utiliser pour filtrer les exécutions de crawler pour un crawler spécifié.

Champs

- **FieldName** – Chaîne UTF-8 (valeurs valides : CRAWL_ID | STATE | START_TIME | END_TIME | DPU_HOUR).

Une clé utilisée pour filtrer les exécutions de Crawler pour un Crawler spécifié. Les valeurs valides pour chacun des noms de champs sont les suivantes :

- **CRAWL_ID** : une chaîne représentant l'identifiant UUID d'une analyse.
- **STATE** : une chaîne représentant l'état de l'analyse.
- **START_TIME** et **END_TIME** : l'horodatage de l'époque en millisecondes.
- **DPU_HOUR** : le nombre d'heures d'unité de traitement de données (DPU) utilisées pour l'analyse.
- **FilterOperator** – Chaîne UTF-8 (valeurs valides : GT | GE | LT | LE | EQ | NE).

Un comparateur défini qui agit sur la valeur. Les opérateurs disponibles sont les suivants :

- **GT** : Supérieur à.
- **GE** : Supérieur ou égal à.
- **LT** : Inférieur à.
- **LE** : Inférieur ou égal à.
- **EQ** : Égal à.
- **NE** : Pas égal à.
- **FieldValue** – Chaîne UTF-8.

La valeur fournie pour la comparaison dans le champ d'analyse.

SchemaChangePolicy structure

Stratégie qui spécifie des comportements de mise à jour et de suppression pour l'crawler.

Champs

- **UpdateBehavior** – Chaîne UTF-8 (valeurs valides : LOG | UPDATE_IN_DATABASE).

Comportement de mise à jour lorsque le crawler détecte un schéma modifié.

- **DeleteBehavior** – Chaîne UTF-8 (valeurs valides : LOG | DELETE_FROM_DATABASE | DEPRECATE_IN_DATABASE).

Comportement de suppression lorsque le crawler détecte un objet supprimé.

LastCrawlInfo structure

Informations d'état et d'erreur sur l'analyse la plus récente.

Champs

- **Status** – Chaîne UTF-8 (valeurs valides : SUCCEEDED | CANCELLED | FAILED).

État de la dernière analyse.

- **ErrorMessage** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Si une erreur s'est produite, informations d'erreur sur la dernière analyse.

- **LogGroup** – Chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets, correspondant au [Log group string pattern](#).

Groupe de journaux de la dernière analyse.

- **LogStream** – Chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets, correspondant au [Log-stream string pattern](#).

Flux de journal de la dernière analyse.

- **MessagePrefix** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Préfixe d'un message sur cette analyse.

- **StartTime** – Horodatage.

Heure à laquelle l'analyse a commencé.

RecrawlPolicy structure

Lorsque vous indexez une source de données Amazon S3 après la première indexation, spécifiez s'il faut indexer à nouveau l'ensemble du jeu de données ou uniquement les dossiers ajoutés depuis la dernière exécution du crawler. Pour de plus amples informations, veuillez consulter la rubrique [Analyses incrémentielles dans AWS Glue](#) dans le guide du développeur.

Champs

- `RecrawlBehavior` – Chaîne UTF-8 (valeurs valides : `CRAWL_EVERYTHING` | `CRAWL_NEW_FOLDERS_ONLY` | `CRAWL_EVENT_MODE`).

Spécifie s'il faut analyser à nouveau le jeu de données ou uniquement les dossiers ajoutés depuis la dernière exécution de l'crawler.

Une valeur de `CRAWL_EVERYTHING` indique que l'ensemble du jeu de données doit être analysé à nouveau.

Une valeur de `CRAWL_NEW_FOLDERS_ONLY` indique que seuls les dossiers ajoutés depuis la dernière exécution du crawler doivent être indexés.

Une valeur de `CRAWL_EVENT_MODE` spécifie uniquement l'analyse des modifications identifiées par les événements Amazon S3.

LineageConfiguration structure

Spécifie les paramètres de configuration de la lignée de données pour l'crawler.

Champs

- `CrawlerLineageSettings` – Chaîne UTF-8 (valeurs valides : `ENABLE` | `DISABLE`).

Indique si la lignée de données est activée pour le crawler. Les valeurs valides sont :

- `ENABLE` : active la lignée des données pour le crawler
- `DISABLE` : désactive la lignée de données pour le crawler

LakeFormationConfiguration structure

Spécifie les paramètres AWS Lake Formation de configuration pour le robot d'exploration.

Champs

- `UseLakeFormationCredentials` – Booléen.

Spécifie s'il faut utiliser les AWS Lake Formation informations d'identification du robot d'exploration au lieu des informations d'identification du rôle IAM.

- `AccountId` – Chaîne UTF-8, d'une longueur maximale de 12 octets.

Obligatoire pour les analyses de compte croisées. Pour les mêmes analyses de compte que les données cibles, cela peut être laissé nul.

Opérations

- [CreateCrawler action \(Python : create_crawler\)](#)
- [DeleteCrawler action \(Python : delete_crawler\)](#)
- [GetCrawler action \(Python : get_crawler\)](#)
- [GetCrawlers action \(Python : get_crawlers\)](#)
- [GetCrawlerMetrics action \(Python : get_crawler_metrics\)](#)
- [UpdateCrawler action \(Python : update_crawler\)](#)
- [StartCrawler action \(Python : start_crawler\)](#)
- [StopCrawler action \(Python : stop_crawler\)](#)
- [BatchGetCrawlers action \(Python : batch_get_crawlers\)](#)
- [ListCrawlers action \(Python : list_crawlers\)](#)
- [ListCrawls action \(Python : list_crawls\)](#)

CreateCrawler action (Python : create_crawler)

Crée un crawler avec des cibles, un rôle, une configuration, et une éventuelle planification spécifiés. Au moins une cible d'analyse doit être spécifiée dans le champ `s3Targets`, le champ `jdbcTargets` ou le champ `DynamoDBTargets`.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du nouveau crawler.

- **Role** – Obligatoire : chaîne UTF-8.

Rôle IAM ou Amazon Resource Name (ARN) d'un rôle IAM utilisé par le nouveau crawler pour accéder aux ressources client.

- **DatabaseName** – Chaîne UTF-8.

La AWS Glue base de données dans laquelle les résultats sont écrits, par exemple `:arn:aws:daylight:us-east-1::database/sometable/*`.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du nouvel crawler.

- **Targets** – Obligatoire : un objet [CrawlerTargets](#).

Liste de l'ensemble de cibles à analyser.

- **Schedule** – Chaîne UTF-8.

Une expression cron utilisée pour spécifier la planification (consultez [Time-Based Schedules for Jobs and Crawlers](#) (Planifications temporelles pour les tâches et les crawlers)). Par exemple, pour exécuter un élément tous les jours à 12h15 UTC, vous devez spécifier : `cron(15 12 * * ? *)`.

- **Classifiers** – Tableau de chaînes UTF-8.

Liste des classifieurs personnalisés que l'utilisateur a enregistrés. Par défaut, tous les classificateurs intégrés sont inclus dans une analyse, mais ces classificateurs personnalisés se substituent toujours aux classificateurs par défaut pour une classification donnée.

- **TablePrefix** – Chaîne UTF-8, d'une longueur maximale de 128 octets.

Préfixe de table utilisé pour les tables catalogue créées.

- **SchemaChangePolicy** – Un objet [SchemaChangePolicy](#).

Stratégie du comportement de mise à jour et de suppression de l'crawler.

- **RecrawlPolicy** – Un objet [RecrawlPolicy](#).

Stratégie qui spécifie s'il faut analyser à nouveau le jeu de données entier ou analyser uniquement les dossiers ajoutés depuis la dernière exécution du crawler.

- **LineageConfiguration** – Un objet [LineageConfiguration](#).

Spécifie les paramètres de configuration de la lignée de données pour le crawler.

- **LakeFormationConfiguration** – Un objet [LakeFormationConfiguration](#).

Spécifie les paramètres AWS Lake Formation de configuration pour le robot d'exploration.

- **Configuration** – Chaîne UTF-8.

Informations sur la configuration du crawler. Cette chaîne JSON avec gestion des versions permet aux utilisateurs de spécifier des aspects du comportement d'un crawler. Pour plus d'informations, consultez [Setting Crawler configuration options](#) (Définition d'options de configuration du crawler).

- `CrawlerSecurityConfiguration` – Chaîne UTF-8, d'une longueur maximale de 128 octets.

Nom de la structure `SecurityConfiguration` qui sera utilisée par ce crawler.

- `Tags` – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Balises à utiliser avec cette demande d'crawler. Vous pouvez utiliser des balises pour limiter l'accès à l'crawler. Pour plus d'informations sur les tags in AWS Glue, voir [AWS Tags in AWS Glue](#) dans le guide du développeur.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `InvalidInputException`
- `AlreadyExistsException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

DeleteCrawler action (Python : `delete_crawler`)

Supprime un robot d'exploration spécifié du AWS Glue Data Catalog, sauf si l'état du robot est `RUNNING`.

Demande

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'crawler à supprimer.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- EntityNotFoundException
- CrawlerRunningException
- SchedulerTransitioningException
- OperationTimeoutException

GetCrawler action (Python : get_crawler)

Récupère des métadonnées pour un crawler spécifié.

Demande

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'crawler pour lequel récupérer les métadonnées.

Réponse

- Crawler – Un objet [crawler](#).

Métadonnées pour l'crawler spécifié.

Erreurs

- EntityNotFoundException
- OperationTimeoutException

GetCrawlers action (Python : `get_crawlers`)

Récupère les métadonnées pour tous les crawlers définis dans le compte client.

Demande

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Nombre d'crawlers à renvoyer à chaque appel.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'une requête de continuation.

Réponse

- `Crawlers` – Un tableau d'objets [crawler](#).

Liste des métadonnées de l'crawler.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, si la liste renvoyée n'a pas atteint la fin de ceux définis dans ce compte client.

Erreurs

- `OperationTimeoutException`

GetCrawlerMetrics action (Python : `get_crawler_metrics`)

Récupère les métriques sur les crawlers spécifiés.

Demande

- `CrawlerNameList` – Tableau de chaînes UTF-8, avec 100 chaînes maximum.

Liste des noms des crawlers sur lesquels récupérer les métriques.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

La taille maximale d'une liste à renvoyer.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- `CrawlerMetricsList` – Un tableau [CrawlerMetrics](#) d'objets.

Liste des métriques pour l'crawler spécifié.

- `NextToken` – Chaîne UTF-8.

Jeton continuation, si la liste renvoyée ne contient pas la dernière métrique disponible.

Erreurs

- `OperationTimeoutException`

UpdateCrawler action (Python : `update_crawler`)

Met à jour un crawler. Si un crawler est en cours d'exécution, vous devez l'arrêter à l'aide de `StopCrawler` avant de le mettre à jour.

Demande

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du nouvel crawler.

- `Role` – Chaîne UTF-8.

Rôle IAM ou Amazon Resource Name (ARN) d'un rôle IAM qui est utilisé par le nouvel crawler pour accéder aux ressources client.

- `DatabaseName` – Chaîne UTF-8.

La AWS Glue base de données dans laquelle les résultats sont stockés, par exemple `:arn:aws:daylight:us-east-1::database/sometable/*`.

- `Description` – Chaîne UTF-8, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du nouvel crawler.

- **Targets** – Un objet [CrawlerTargets](#).

Liste des cibles à analyser.

- **Schedule** – Chaîne UTF-8.

Une expression cron utilisée pour spécifier la planification (consultez [Time-Based Schedules for Jobs and Crawlers](#) (Planifications temporelles pour les tâches et les crawlers)). Par exemple, pour exécuter un élément tous les jours à 12h15 UTC, vous devez spécifier : `cron(15 12 * * ? *)`.

- **Classifiers** – Tableau de chaînes UTF-8.

Liste des classifieurs personnalisés que l'utilisateur a enregistrés. Par défaut, tous les classificateurs intégrés sont inclus dans une analyse, mais ces classificateurs personnalisés se substituent toujours aux classificateurs par défaut pour une classification donnée.

- **TablePrefix** – Chaîne UTF-8, d'une longueur maximale de 128 octets.

Préfixe de table utilisé pour les tables catalogue créées.

- **SchemaChangePolicy** – Un objet [SchemaChangePolicy](#).

Stratégie du comportement de mise à jour et de suppression de l'crawler.

- **RecrawlPolicy** – Un objet [RecrawlPolicy](#).

Stratégie qui spécifie s'il faut analyser à nouveau le jeu de données entier ou analyser uniquement les dossiers ajoutés depuis la dernière exécution du crawler.

- **LineageConfiguration** – Un objet [LineageConfiguration](#).

Spécifie les paramètres de configuration de la lignée de données pour le crawler.

- **LakeFormationConfiguration** – Un objet [LakeFormationConfiguration](#).

Spécifie les paramètres AWS Lake Formation de configuration pour le robot d'exploration.

- **Configuration** – Chaîne UTF-8.

Informations sur la configuration du crawler. Cette chaîne JSON avec gestion des versions permet aux utilisateurs de spécifier des aspects du comportement d'un crawler. Pour plus d'informations, consultez [Setting Crawler configuration options](#) (Définition d'options de configuration du crawler).

- **CrawlerSecurityConfiguration** – Chaîne UTF-8, d'une longueur maximale de 128 octets.

Nom de la structure `SecurityConfiguration` qui sera utilisée par cet crawler.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `InvalidInputException`
- `VersionMismatchException`
- `EntityNotFoundException`
- `CrawlerRunningException`
- `OperationTimeoutException`

StartCrawler action (Python : `start_crawler`)

Démarre une analyse à l'aide de l'crawler, indépendamment de ce qui est prévu. Si le robot d'exploration est déjà en cours d'exécution, renvoie un [CrawlerRunningException](#).

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'crawler à démarrer.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `CrawlerRunningException`
- `OperationTimeoutException`

StopCrawler action (Python : stop_crawler)

Si l'crawler spécifié est en cours d'exécution, arrête l'analyse.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'crawler à arrêter.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `CrawlerNotRunningException`
- `CrawlerStoppingException`
- `OperationTimeoutException`

BatchGetCrawlers action (Python : batch_get_crawlers)

Renvoie la liste des métadonnées de ressource pour une liste donnée de noms d'crawler. Après avoir appelé l'opération `ListCrawlers`, vous pouvez appeler cette opération pour accéder aux données sur lesquelles des autorisations vous ont été octroyées. Cette opération prend en charge toutes les autorisations IAM, y compris les conditions d'autorisation qui utilisent des balises.

Demande

- **CrawlerNames** – Obligatoire : Tableau de chaînes UTF-8, avec 100 chaînes maximum.

Liste des noms d'crawler, qui peuvent être les noms renvoyés à partir de l'opération `ListCrawlers`.

Réponse

- `Crawlers` – Un tableau [crawler](#) d'objets.

Liste des définitions d'crawler.

- `CrawlersNotFound` – Tableau de chaînes UTF-8, avec 100 chaînes maximum.

Liste de noms d'crawler qui n'ont pas été trouvés.

Erreurs

- `InvalidInputException`
- `OperationTimeoutException`

ListCrawlers action (Python : `list_crawlers`)

Récupère les noms de toutes les ressources du robot d'exploration de ce AWS compte, ou des ressources portant le tag spécifié. Cette opération vous permet de voir quelles ressources sont disponibles dans votre compte, et leurs noms.

Cette opération accepte le champ `Tags` facultatif que vous pouvez utiliser comme filtre sur la réponse, afin que les ressources balisées puissent être récupérées en tant que groupe. Si vous choisissez d'utiliser le filtrage des balises, seules les ressources avec la balise sont récupérées.

Demande

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

La taille maximale d'une liste à renvoyer.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'une requête de continuation.

- `Tags` – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Spécifie de renvoyer uniquement les ressources balisées.

Réponse

- `CrawlerNames` – Tableau de chaînes UTF-8, avec 100 chaînes maximum.

Noms de tous les crawlers dans le compte ou des crawlers avec les balises spécifiées.

- `NextToken` – Chaîne UTF-8.

Jeton continuation, si la liste renvoyée ne contient pas la dernière métrique disponible.

Erreurs

- `OperationTimeoutException`

ListCrawls action (Python : `list_crawls`)

Renvoie toutes les analyse d'un Crawler spécifié. Renvoie uniquement les analyses qui ont eu lieu depuis la date de lancement de la fonction d'historique du Crawler, et ne retient que jusqu'à 12 mois d'analyse. Les anciennes analyses ne seront pas renvoyées.

Vous pouvez utiliser cette API pour :

- Récupère toutes les analyse d'un Crawler spécifié.
- Récupère toutes les analyse d'un Crawler spécifié dans un nombre limité.
- Récupère toutes les analyse d'un Crawler spécifié dans une plage de temps spécifique.
- Récupère toutes les analyse d'un Crawler spécifié avec un état, un ID d'analyse ou une valeur d'heure DPU particuliers.

Demande

- `CrawlerName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du Crawler dont vous voulez récupérer les exécutions.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats à renvoyer. La valeur par défaut est 20 et la valeur maximale est 100.

- `Filters` – Un tableau d'objets [CrawlsFilter](#).

Filtre les analyse en fonction de critères que vous spécifiez dans une liste objets `CrawlsFilter`.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- `Crawls` – Un tableau d'objets [CrawlerHistory](#).

Une liste d'objets `CrawlerHistory` représentant les cycles d'analyse qui répondent à vos critères.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation pour la pagination de la liste des jetons renvoyés, renvoyé si le segment actuel de la liste n'est pas le dernier.

Erreurs

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`

API de statistiques de colonne

L'API de statistiques de colonnes décrit comment renvoyer AWS Glue APIs des statistiques sur les colonnes d'une table.

Types de données

- [ColumnStatisticsTaskRun structure](#)
- [ColumnStatisticsTaskSettings structure](#)
- [ExecutionAttempt structure](#)

ColumnStatisticsTaskRun structure

L'objet qui affiche les détails de l'exécution des statistiques de colonne.

Champs

- `CustomerId` – Chaîne UTF-8, d'une longueur maximale de 12 octets.

L'identifiant AWS du compte.

- `ColumnStatisticsTaskRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant d'exécution de la tâche de statistiques de colonne particulière.

- `DatabaseName` – Chaîne UTF-8.

La base de données où réside la table.

- `TableName` – Chaîne UTF-8.

Le nom de la table pour laquelle les statistiques de colonne sont générées.

- `ColumnNameList` – Tableau de chaînes UTF-8.

Une liste des noms de colonnes. Si aucun nom n'est fourni, tous les noms de colonnes de la table seront utilisés par défaut.

- `CatalogID` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données où réside la table. Si aucun identifiant n'est fourni, l'identifiant du AWS compte est utilisé par défaut.

- `Role` – Chaîne UTF-8.

Le rôle IAM que le service assume pour générer des statistiques.

- `SampleSize` – Nombre (double), 100 au maximum.

Pourcentage de lignes utilisées pour générer des statistiques. Si aucun nom n'est fourni, la table entière sera utilisée pour générer des statistiques.

- `SecurityConfiguration` – Chaîne UTF-8, d'une longueur maximale de 128 octets.

Nom de la configuration de sécurité utilisée pour chiffrer les CloudWatch journaux pour la tâche de statistiques de colonne exécutée.

- `NumberOfWorkers` – Nombre (entier), au moins égal à 1.

Le nombre d'employés utilisés pour générer les statistiques de colonne. La tâche est préconfigurée pour effectuer une mise à l'échelle automatique jusqu'à 25 instances.

- `WorkerType` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Type de travailleurs utilisés pour générer des statistiques. L'argument par défaut est `g.1x`.

- `ComputationType` – Chaîne UTF-8 (valeurs valides : `FULL` | `INCREMENTAL`).

Type de calcul des statistiques de colonne.

- `Status` – Chaîne UTF-8 (valeurs valides : `STARTING` | `RUNNING` | `SUCCEEDED` | `FAILED` | `STOPPED`).

L'état d'exécution de la tâche.

- `CreationTime` – Horodatage.

Heure à laquelle cette tâche a été créée.

- `LastUpdated` – Horodatage.

Dernier moment où cette tâche a été modifiée.

- `StartTime` – Horodatage.

L'heure de début de la tâche.

- `EndTime` – Horodatage.

L'heure de fin de la tâche.

- `ErrorMessage` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Le message d'erreur pour la tâche.

- `DPUSeconds` – Nombre (double), pas plus qu'Aucun.

L'utilisation de la DPU calculée en secondes pour tous les travailleurs mis à l'échelle automatique.

ColumnStatisticsTaskSettings structure

Les paramètres d'une tâche de statistiques de colonnes.

Champs

- `DatabaseName` – Chaîne UTF-8.

Le nom de la base de données où réside la table.

- `TableName` – Chaîne UTF-8.

Nom de la table pour laquelle les statistiques de colonne doivent être générées.

- `Schedule` – Un objet [Planificateur](#).

Un calendrier d'exécution des statistiques de colonne, spécifié dans la syntaxe CRON.

- `ColumnNameList` – Tableau de chaînes UTF-8.

Liste des noms de colonnes pour lesquelles les statistiques doivent être exécutées.

- `CatalogID` – Chaîne d'ID de catalogue, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la base de données.

- `Role` – Chaîne UTF-8.

Rôle utilisé pour exécuter les statistiques des colonnes.

- `SampleSize` – Nombre (double), 100 au maximum.

Pourcentage de données à échantillonner.

- `SecurityConfiguration` – Chaîne UTF-8, d'une longueur maximale de 128 octets.

Nom de la configuration de sécurité utilisée pour chiffrer les CloudWatch journaux.

- `ScheduleType` – Chaîne UTF-8 (valeurs valides : CRON | AUTO).

Type de planification pour une tâche de statistiques de colonnes. Les valeurs possibles peuvent être CRON ou AUTO.

- `SettingSource` – Chaîne UTF-8 (valeurs valides : CATALOG | TABLE).

Source de définition de la tâche de statistiques sur les colonnes. Les valeurs possibles peuvent être CATALOG ou TABLE.

- `LastExecutionAttempt` – Un objet [ExecutionAttempt](#).

Le dernier `ExecutionAttempt` pour la tâche de statistiques de colonne exécutée.

ExecutionAttempt structure

Tentative d'exécution d'une tâche de statistiques de colonne exécutée.

Champs

- **Status** – Chaîne UTF-8 (valeurs valides : FAILED | STARTED).

État de la dernière tâche de statistiques de colonne exécutée.

- **ColumnStatisticsTaskRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution de tâche pour la dernière tâche de statistiques de colonne exécutée.

- **ExecutionTimestamp** – Horodatage.

Horodatage de la dernière tâche de statistiques de colonne exécutée.

- **ErrorMessage** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Message d'erreur associé à la dernière tâche de statistiques de colonne exécutée.

Opérations

- [StartColumnStatisticsTaskRun action \(Python : start_column_statistics_task_run\)](#)
- [GetColumnStatisticsTaskRun action \(Python : get_column_statistics_task_run\)](#)
- [GetColumnStatisticsTaskRuns action \(Python : get_column_statistics_task_runs\)](#)
- [ListColumnStatisticsTaskRuns action \(Python : list_column_statistics_task_runs\)](#)
- [StopColumnStatisticsTaskRun action \(Python : stop_column_statistics_task_run\)](#)
- [CreateColumnStatisticsTaskSettings action \(Python : create_column_statistics_task_settings\)](#)
- [UpdateColumnStatisticsTaskSettings action \(Python : update_column_statistics_task_settings\)](#)
- [GetColumnStatisticsTaskSettings action \(Python : get_column_statistics_task_settings\)](#)
- [DeleteColumnStatisticsTaskSettings action \(Python : delete_column_statistics_task_settings\)](#)
- [StartColumnStatisticsTaskRunSchedule action \(Python : start_column_statistics_task_run_schedule\)](#)
- [StopColumnStatisticsTaskRunSchedule action \(Python : stop_column_statistics_task_run_schedule\)](#)

StartColumnStatisticsTaskRun action (Python : start_column_statistics_task_run)

Démarre une exécution de tâche de statistiques de colonne pour une table et des colonnes spécifiées.

Demande

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la base de données où réside la table.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la table pour générer des statistiques.

- **ColumnNameList** – Tableau de chaînes UTF-8.

Une liste des noms de colonnes pour générer des statistiques. Si aucun nom n'est fourni, tous les noms de colonnes de la table seront utilisés par défaut.

- **Role** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le rôle IAM que le service assume pour générer des statistiques.

- **SampleSize** – Nombre (double), 100 au maximum.

Pourcentage de lignes utilisées pour générer des statistiques. Si aucun nom n'est fourni, la table entière sera utilisée pour générer des statistiques.

- **CatalogID** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID du catalogue de données où réside la table. Si aucun nom n'est fourni, l'ID de compte AWS est utilisé par défaut.

- **SecurityConfiguration** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité utilisée pour chiffrer les CloudWatch journaux pour la tâche de statistiques de colonne exécutée.

Réponse

- `ColumnStatisticsTaskRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant d'exécution de la tâche de statistiques de colonne.

Erreurs

- `AccessDeniedException`
- `EntityNotFoundException`
- `ColumnStatisticsTaskRunningException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `InvalidInputException`

GetColumnStatisticsTaskRun action (Python : `get_column_statistics_task_run`)

Obtenez les métadonnées/informations associées à une exécution de tâche, en fonction d'un ID d'exécution de tâche.

Demande

- `ColumnStatisticsTaskRunId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant d'exécution de la tâche de statistiques de colonne particulière.

Réponse

- `ColumnStatisticsTaskRun` – Un objet [ColumnStatisticsTaskRun](#).

Un objet `ColumnStatisticsTaskRun` représentant les détails de l'exécution des statistiques de colonne.

Erreurs

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`

GetColumnStatisticsTaskRuns action (Python : `get_column_statistics_task_runs`)

Récupère des informations sur toutes les exécutions associées à la table spécifiée.

Demande

- `DatabaseName` – Obligatoire : chaîne UTF-8.

Le nom de la base de données où réside la table.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Taille maximale de la réponse.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- `ColumnStatisticsTaskRuns` – Un tableau d'objets [ColumnStatisticsTaskRun](#).

Une liste des exécutions de tâches de statistiques de colonne.

- `NextToken` – Chaîne UTF-8.

Un jeton de continuation, si toutes les exécutions de tâches n'ont pas encore été renvoyées.

Erreurs

- `OperationTimeoutException`

ListColumnStatisticsTaskRuns action (Python : `list_column_statistics_task_runs`)

Répertoriez toutes les exécutions de tâches pour un compte spécifique.

Demande

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Taille maximale de la réponse.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- `ColumnStatisticsTaskRunIds` – Tableau de chaînes UTF-8, avec 100 chaînes maximum.

Liste des tâches de statistiques de colonnes exécutées IDs.

- `NextToken` – Chaîne UTF-8.

Un jeton de continuation, si toutes les tâches exécutées n' IDs ont pas encore été renvoyées.

Erreurs

- `OperationTimeoutException`

StopColumnStatisticsTaskRun action (Python : `stop_column_statistics_task_run`)

Arrête l'exécution d'une tâche pour la table spécifiée.

Demande

- `DatabaseName` – Obligatoire : chaîne UTF-8.

Le nom de la base de données où réside la table.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `ColumnStatisticsTaskNotRunningException`
- `ColumnStatisticsTaskStoppingException`
- `OperationTimeoutException`

CreateColumnStatisticsTaskSettings action (Python : `create_column_statistics_task_settings`)

Crée les paramètres d'une tâche de statistiques de colonnes.

Demande

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la base de données où réside la table.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table pour laquelle les statistiques de colonne doivent être générées.

- `Role` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Rôle utilisé pour exécuter les statistiques des colonnes.

- `Schedule` – Chaîne UTF-8.

Un calendrier d'exécution des statistiques de colonne, spécifié dans la syntaxe CRON.

- `ColumnNameList` – Tableau de chaînes UTF-8.

Liste des noms de colonnes pour lesquelles les statistiques doivent être exécutées.

- `SampleSize` – Nombre (double), 100 au maximum.

Pourcentage de données à échantillonner.

- CatalogID – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la base de données.

- SecurityConfiguration – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité utilisée pour chiffrer les CloudWatch journaux.

- Tags – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Une carte des tags.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- AlreadyExistsException
- AccessDeniedException
- EntityNotFoundException
- InvalidInputException
- OperationTimeoutException
- ResourceNumberLimitExceededException
- ColumnStatisticsTaskRunningException

UpdateColumnStatisticsTaskSettings action (Python :
update_column_statistics_task_settings)

Met à jour les paramètres d'une tâche de statistiques de colonne.

Demande

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la base de données où réside la table.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table pour laquelle les statistiques de colonne doivent être générées.

- **Role** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Rôle utilisé pour exécuter les statistiques des colonnes.

- **Schedule** – Chaîne UTF-8.

Un calendrier d'exécution des statistiques de colonne, spécifié dans la syntaxe CRON.

- **ColumnNameList** – Tableau de chaînes UTF-8.

Liste des noms de colonnes pour lesquelles les statistiques doivent être exécutées.

- **SampleSize** – Nombre (double), 100 au maximum.

Pourcentage de données à échantillonner.

- **CatalogID** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du catalogue de données dans lequel réside la base de données.

- **SecurityConfiguration** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité utilisée pour chiffrer les CloudWatch journaux.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `AccessDeniedException`
- `EntityNotFoundException`
- `InvalidInputException`
- `VersionMismatchException`
- `OperationTimeoutException`

GetColumnStatisticsTaskSettings action (Python : `get_column_statistics_task_settings`)

Obtient les paramètres d'une tâche de statistiques de colonne.

Demande

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la base de données où réside la table.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table pour laquelle vous souhaitez récupérer les statistiques des colonnes.

Réponse

- `ColumnStatisticsTaskSettings` – Un objet [ColumnStatisticsTaskSettings](#).

`ColumnStatisticsTaskSettingsObjet` représentant les paramètres de la tâche de statistiques sur les colonnes.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

DeleteColumnStatisticsTaskSettings action (Python : delete_column_statistics_task_settings)

Supprime les paramètres d'une tâche de statistiques de colonne.

Demande

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la base de données où réside la table.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table pour laquelle les statistiques de colonne doivent être supprimées.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

StartColumnStatisticsTaskRunSchedule action (Python : start_column_statistics_task_run_schedule)

Démarre le calendrier d'exécution d'une tâche de statistiques sur les colonnes.

Demande

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la base de données où réside la table.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table pour laquelle démarrer un calendrier d'exécution d'une tâche de statistiques par colonne.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `AccessDeniedException`
- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

StopColumnStatisticsTaskRunSchedule action (Python : `stop_column_statistics_task_run_schedule`)

Arrête le calendrier d'exécution d'une tâche de statistiques de colonne.

Demande

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la base de données où réside la table.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table pour laquelle arrêter le calendrier d'exécution d'une tâche de statistiques de colonne.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

Exceptions

- [ColumnStatisticsTaskRunningException structure](#)
- [ColumnStatisticsTaskNotRunningException structure](#)
- [ColumnStatisticsTaskStoppingException structure](#)
- [ColumnStatisticsTaskAutoConcurrencyLimitException structure](#)
- [InvalidCatalogSettingException structure](#)

ColumnStatisticsTaskRunningException structure

Exception renvoyée lorsque vous essayez de démarrer une autre tâche lors de l'exécution d'une tâche de génération de statistiques de colonne.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

ColumnStatisticsTaskNotRunningException structure

Exception renvoyée lorsque vous essayez d'arrêter l'exécution d'une tâche alors qu'aucune tâche n'est en cours d'exécution.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

ColumnStatisticsTaskStoppingException structure

Exception renvoyée lorsque vous essayez d'arrêter l'exécution d'une tâche.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

ColumnStatisticsTaskAutoConcurrencyLimitException structure

Une exception est déclenchée lorsque vous avez déjà atteint la limite des tâches de statistiques automatiques simultanées.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

InvalidCatalogSettingException structure

Une exception est déclenchée en cas de problème avec les paramètres du catalogue.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

API du planificateur du crawler

L'API du planificateur de robots décrit les types de données des robots d' AWS Glue exploration, ainsi que l'API permettant de créer, de supprimer, de mettre à jour et de répertorier les robots d'exploration.

Types de données

- [Structure du planificateur](#)

Structure du planificateur

Objet de planification utilisant une instruction `cron` pour planifier un événement.

Champs

- `ScheduleExpression` – Chaîne UTF-8.

Une expression `cron` utilisée pour spécifier la planification (consultez [Time-Based Schedules for Jobs and Crawlers](#) (Planifications temporelles pour les tâches et les crawlers)). Par exemple, pour exécuter un élément tous les jours à 12h15 UTC, vous devez spécifier : `cron(15 12 * * ? *)`.

- `State` – Chaîne UTF-8 (valeurs valides : `SCHEDULED` | `NOT_SCHEDULED` | `TRANSITIONING`).

État de la planification.

Opérations

- [UpdateCrawlerSchedule action \(Python : `update\_crawler\_schedule`\)](#)
- [StartCrawlerSchedule action \(Python : `start\_crawler\_schedule`\)](#)
- [StopCrawlerSchedule action \(Python : `stop\_crawler\_schedule`\)](#)

UpdateCrawlerSchedule action (Python : `update_crawler_schedule`)

Met à jour la planification d'un crawler à l'aide d'une expression `cron`.

Demande

- `CrawlerName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'crawler dont la planification doit être mise à jour.

- `Schedule` – Chaîne UTF-8.

L'expression `cron` mise à jour utilisée pour spécifier la planification (voir [Planifications temporelles pour les tâches et les crawlers](#)). Par exemple, pour exécuter un élément tous les jours à 12h15 UTC, vous devez spécifier : `cron(15 12 * * ? *)`.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- EntityNotFoundException
- InvalidInputException
- VersionMismatchException
- SchedulerTransitioningException
- OperationTimeoutException

StartCrawlerSchedule action (Python : start_crawler_schedule)

Modifie l'état de la planification pour l'crawler spécifié par SCHEDULED, sauf si l'crawler est déjà en cours d'exécution ou si l'état de la planification est déjà SCHEDULED.

Demande

- CrawlerName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'crawler à planifier.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- EntityNotFoundException
- SchedulerRunningException
- SchedulerTransitioningException
- NoScheduleException
- OperationTimeoutException

StopCrawlerSchedule action (Python : stop_crawler_schedule)

Définit l'état de la planification de l'crawler spécifié sur NOT_SCHEDULED, mais n'arrête pas l'crawler s'il est déjà en cours d'exécution.

Demande

- **CrawlerName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'crawler dont l'état de la planification doit être défini.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `SchedulerNotRunningException`
- `SchedulerTransitioningException`
- `OperationTimeoutException`

Génération automatique d'API de scripts ETL

L'API de génération de script ETL décrit les types de données et l'API pour générer les scripts ETL dans AWS Glue.

Types de données

- [CodeGenNode structure](#)
- [CodeGenNodeArg structure](#)
- [CodeGenEdge structure](#)
- [Structure de l'emplacement](#)
- [CatalogEntry structure](#)
- [MappingEntry structure](#)

CodeGenNode structure

Représente un nœud dans un graphe orienté acyclique (DAG)

Champs

- **Id** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Identifiant string pattern](#).

Identifiant de nœud qui est unique dans le graphe du nœud.

- **NodeType** – Obligatoire : chaîne UTF-8.

Type de nœud.

- **Args** – Obligatoire : Un tableau d'objets [CodeGenNodeArg](#), 50 structures maximum.

Propriétés du nœud, sous forme de paires nom-valeur.

- **LineNumber** – Nombre (entier).

Numéro de ligne du nœud.

CodeGenNodeArg structure

Argument ou propriété d'un nœud.

Champs

- **Name** – Obligatoire : chaîne UTF-8.

Nom de l'argument ou de la propriété.

- **Value** – Obligatoire : chaîne UTF-8.

Valeur de l'argument ou de la propriété.

- **Param** – Booléen.

True si la valeur est utilisée en tant que paramètre.

CodeGenEdge structure

Représente un bord directionnel dans un graphe orienté acyclique (DAG).

Champs

- **Source** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Identifier string pattern](#).

ID du nœud où commence le bord.

- **Target** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Identifier string pattern](#).

ID du nœud où finit le bord.

- **TargetParameter** – Chaîne UTF-8.

Cible du bord.

Structure de l'emplacement

Emplacement des ressources.

Champs

- **Jdbc** – Un tableau d'objets [CodeGenNodeArg](#), 50 structures maximum.

Emplacement JDBC.

- **S3** – Un tableau d'objets [CodeGenNodeArg](#), 50 structures maximum.

Emplacement Amazon Simple Storage Service (Amazon S3).

- **DynamoDB** – Un tableau d'objets [CodeGenNodeArg](#), 50 structures maximum.

Emplacement de table Amazon DynamoDB.

CatalogEntry structure

Spécifie une définition de table dans AWS Glue Data Catalog.

Champs

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Base de données dans laquelle réside les métadonnées de la table.

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table en question.

MappingEntry structure

Définit un mappage.

Champs

- `SourceTable` – Chaîne UTF-8.

Nom de la table source.

- `SourcePath` – Chaîne UTF-8.

Le chemin d'accès source .

- `SourceType` – Chaîne UTF-8.

Type source.

- `TargetTable` – Chaîne UTF-8.

Table cible.

- `TargetPath` – Chaîne UTF-8.

Chemin cible.

- `TargetType` – Chaîne UTF-8.

Type de cible.

Opérations

- [CreateScript action \(Python : créer_script\)](#)
- [GetDataflowGraph action \(Python : get_dataflow_graph\)](#)
- [GetMapping action \(Python : get_mapping\)](#)
- [GetPlan action \(Python : get_plan\)](#)

CreateScript action (Python : créer_script)

Transforme un graphe orienté acyclique (DAG) en code.

Demande

- DagNodes – Un tableau d'objets [CodeGenNode](#).

Liste de nœuds dans le DAG.

- DagEdges – Un tableau d'objets [CodeGenEdge](#).

Liste de bords dans le DAG.

- Language – Chaîne UTF-8 (valeurs valides : PYTHON | SCALA).

Langage de programmation du code obtenu à partir du DAG.

Réponse

- PythonScript – Chaîne UTF-8.

Script Python généré à partir du DAG.

- ScalaCode – Chaîne UTF-8.

Code Scala généré à partir du DAG.

Erreurs

- InvalidInputException
- InternalServiceException
- OperationTimeoutException

GetDataflowGraph action (Python : get_dataflow_graph)

Transforme un script Python en graphe orienté acyclique (DAG).

Demande

- PythonScript – Chaîne UTF-8.

Script Python à transformer.

Réponse

- DagNodes – Un tableau d'objets [CodeGenNode](#).

Liste de nœuds dans le DAG obtenu.

- DagEdges – Un tableau d'objets [CodeGenEdge](#).

Liste de bords dans le DAG obtenu.

Erreurs

- InvalidInputException
- InternalServiceException
- OperationTimeoutException

GetMapping action (Python : get_mapping)

Crée des mappages.

Demande

- Source – Obligatoire : un objet [CatalogEntry](#).

Spécifie la table source.

- Sinks – Un tableau d'objets [CatalogEntry](#).

Liste des tables cible.

- Location – Un objet [Emplacement](#).

Paramètres pour le mappage.

Réponse

- Mapping – Obligatoire : Un tableau d'objets [MappingEntry](#).

Liste des mappages pour les cibles spécifiées.

Erreurs

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `EntityNotFoundException`

GetPlan action (Python : `get_plan`)

Obtient le code pour effectuer un mappage spécifié.

Demande

- Mapping – Obligatoire : Un tableau d'objets [MappingEntry](#).

Liste des mappages d'une table source vers des tables cibles.

- Source – Obligatoire : un objet [CatalogEntry](#).

Table source.

- Sinks – Un tableau [CatalogEntry](#) d'objets.

Tables cibles.

- Location – Un objet [Emplacement](#).

Paramètres pour le mappage.

- Language – Chaîne UTF-8 (valeurs valides : PYTHON | SCALA).

Langage de programmation du code pour effectuer le mappage.

- `AdditionalPlanOptionsMap` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Carte pour contenir les paramètres clé-valeur facultatifs supplémentaires.

Actuellement, ces paires clé-valeur sont prises en charge :

- `inferSchema`— Spécifie si le script par défaut généré par une AWS Glue tâche doit `inferSchema` être défini sur `true` ou `false`. Par exemple, pour définir `inferSchema` sur `true`, transmettez la paire de clé-valeur suivante :

```
--additional-plan-options-map '{"inferSchema":"true"}'
```

Réponse

- `PythonScript` – Chaîne UTF-8.

Script Python pour effectuer le mappage.

- `ScalaCode` – Chaîne UTF-8.

Code Scala pour effectuer le mappage.

Erreurs

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

API Visual Job

L'API Visual Job vous permet de créer des jobs d'intégration de données en utilisant l' AWS Glue API à partir d'un objet JSON qui représente une configuration visuelle d'un AWS Glue job.

Une liste est fournie à une API de `CodeGenConfigurationNodes` création ou de mise à jour de tâche afin d'enregistrer un DAG dans AWS Glue Studio pour la tâche créée et de générer le code associé.

Types de données

- [CodeGenConfigurationNode structure](#)
- [JDBCConnectorStructure des options](#)
- [StreamingDataPreviewOptions structure](#)

- [AthenaConnectorSource structure](#)
- [JDBCConnectorStructure de la source](#)
- [SparkConnectorSource structure](#)
- [CatalogSource structure](#)
- [Structure SQLCatalog de ma source](#)
- [Structure de la SQLCatalog source Postgre](#)
- [Structure d'Oracle SQLCatalog Source](#)
- [SQLServerCatalogSource Structure de Microsoft](#)
- [CatalogKinesisSource structure](#)
- [DirectKinesisSource structure](#)
- [KinesisStreamingSourceOptions structure](#)
- [CatalogKafkaSource structure](#)
- [DirectKafkaSource structure](#)
- [KafkaStreamingSourceOptions structure](#)
- [RedshiftSource structure](#)
- [AmazonRedshiftSource structure](#)
- [AmazonRedshiftNodeData structure](#)
- [AmazonRedshiftAdvancedOption structure](#)
- [Structure de l'option](#)
- [CatalogSource Structure S3](#)
- [SourceAdditionalOptions Structure S3](#)
- [CsvSource Structure S3](#)
- [JDBCSource Structure directe](#)
- [DirectSourceAdditionalOptions Structure S3](#)
- [JsonSource Structure S3](#)
- [ParquetSource Structure S3](#)
- [DeltaSource Structure S3](#)
- [CatalogDeltaSource Structure S3](#)
- [CatalogDeltaSource structure](#)

- [HudiSource Structure S3](#)
- [CatalogHudiSource Structure S3](#)
- [ExcelSource Structure S3](#)
- [CatalogHudiSource structure](#)
- [Structure de Dynamo DBCatalog Source](#)
- [RelationalCatalogSource structure](#)
- [JDBCConnectorStructure de la cible](#)
- [SparkConnectorTarget structure](#)
- [BasicCatalogTarget structure](#)
- [Structure de My SQLCatalog Target](#)
- [Structure de SQLCatalog PostgreTarget](#)
- [Structure d'Oracle SQLCatalog Target](#)
- [SQLServerCatalogTarget Structure de Microsoft](#)
- [RedshiftTarget structure](#)
- [AmazonRedshiftTarget structure](#)
- [UpsertRedshiftTargetOptions structure](#)
- [CatalogTarget Structure S3](#)
- [GlueParquetTarget Structure S3](#)
- [CatalogSchemaChangePolicy structure](#)
- [DirectTarget Structure S3](#)
- [HudiCatalogTarget Structure S3](#)
- [HudiDirectTarget Structure S3](#)
- [DeltaCatalogTarget Structure S3](#)
- [DeltaDirectTarget Structure S3](#)
- [HyperDirectTarget Structure S3](#)
- [IcebergDirectTarget Structure S3](#)
- [DirectSchemaChangePolicy structure](#)
- [ApplyMapping structure](#)
- [Structure de mappage](#)

- [SelectFields structure](#)
- [DropFields structure](#)
- [RenameField structure](#)
- [Structure Spigot](#)
- [Structure Join](#)
- [JoinColumn structure](#)
- [SplitFields structure](#)
- [SelectFromCollection structure](#)
- [FillMissingValues structure](#)
- [Structure Filtre](#)
- [FilterExpression structure](#)
- [FilterValue structure](#)
- [CustomCode structure](#)
- [Structure SparkSQL](#)
- [SqlAlias structure](#)
- [DropNullFields structure](#)
- [NullCheckBoxList structure](#)
- [NullValueField structure](#)
- [Structure Datatype](#)
- [Structure Fusion](#)
- [Structure Union](#)
- [PIIDetection structure](#)
- [Structure Aggregate](#)
- [DropDuplicates structure](#)
- [GovernedCatalogTarget structure](#)
- [GovernedCatalogSource structure](#)
- [AggregateOperation structure](#)
- [GlueSchema structure](#)
- [GlueStudioSchemaColumn structure](#)

- [GlueStudioColumn structure](#)
- [DynamicTransform structure](#)
- [TransformConfigParameter structure](#)
- [EvaluateDataQuality structure](#)
- [DQResultsPublishingOptions structure](#)
- [DQStopJobOnFailureOptions structure](#)
- [EvaluateDataQualityMultiFrame structure](#)
- [Structure de la recette](#)
- [RecipeReference structure](#)
- [SnowflakeNodeData structure](#)
- [SnowflakeSource structure](#)
- [SnowflakeTarget structure](#)
- [ConnectorDataSource structure](#)
- [ConnectorDataTarget structure](#)
- [RecipeStep structure](#)
- [RecipeAction structure](#)
- [ConditionExpression structure](#)

CodeGenConfigurationNode structure

CodeGenConfigurationNode Il énumère les différents types de nœuds valides. Une seule et unique de ses variables membres peut être renseignée.

Champs

- AthenaConnectorSource – Un objet [AthenaConnectorSource](#).

Indique un connecteur à une source de données Amazon Athena.

- JDBCConectorSource – Un objet [JDBCConectorLa source](#).

Indique un connecteur à une source de données JDBC.

- SparkConnectorSource – Un objet [SparkConnectorSource](#).

Indique un connecteur à une source de données Apache Spark.

- `CatalogSource` – Un objet [CatalogSource](#).

Spécifie un magasin de données dans le catalogue de AWS Glue données.

- `RedshiftSource` – Un objet [RedshiftSource](#).

Indique un stocker de données Amazon Redshift.

- `S3CatalogSource` – Un objet [S3 CatalogSource](#).

Spécifie un magasin de données Amazon S3 dans le catalogue de AWS Glue données.

- `S3CsvSource` – Objet [S3 CsvSource](#).

Indique un stocker de données CSV (valeurs séparées par commande) stocké dans Amazon S3.

- `S3ExcelSource` – Un objet [S3 ExcelSource](#).

Définit les paramètres de configuration pour lire les fichiers Excel depuis Amazon S3.

- `S3JsonSource` – Un objet [S3 JsonSource](#).

Indique un stocker de données JSON stocké dans Amazon S3.

- `S3ParquetSource` – Un objet [S3 ParquetSource](#).

Indique un stocker de données Apache Parquet stocké dans Amazon S3.

- `RelationalCatalogSource` – Un objet [RelationalCatalogSource](#).

Spécifie un magasin de données de catalogue relationnel dans le catalogue de AWS Glue données.

- `DynamoDBCatalogSource` – Un objet [Source de dynamo DBCatalog](#).

Spécifie un magasin de données du catalogue DynamoDBC dans le catalogue de AWS Glue données.

- `JDBCConnectorTarget` – Un objet [JDBCConnectorCible](#).

Indique une cible de données qui écrit sur Amazon S3 dans un stockage en colonnes Apache Parquet.

- `SparkConnectorTarget` – Un objet [SparkConnectorTarget](#).

Indique une cible qui utilise un connecteur Apache Spark.

- CatalogTarget – Un objet [BasicCatalogTarget](#).

Spécifie une cible qui utilise une table AWS Glue de catalogue de données.

- RedshiftTarget – Un objet [RedshiftTarget](#).

Indique une cible qui utilise Amazon Redshift.

- S3CatalogTarget – Un objet [S3 CatalogTarget](#).

Spécifie une cible de données qui écrit sur Amazon S3 à l'aide du catalogue de AWS Glue données.

- S3GlueParquetTarget – Un objet [S3 GlueParquetTarget](#).

Indique une cible de données qui écrit sur Amazon S3 dans un stockage en colonnes Apache Parquet.

- S3HyperDirectTarget – Un objet [S3 HyperDirectTarget](#).

Définit les paramètres de configuration pour écrire des données sur Amazon S3 à l'aide de l'HyperDirect optimisation.

- S3DirectTarget – Un objet [S3 DirectTarget](#).

Indique une cible de données qui écrit dans Amazon S3.

- S3IcebergDirectTarget – Un objet [S3 IcebergDirectTarget](#).

Définit les paramètres de configuration pour écrire des données sur Amazon S3 sous forme de table Apache Iceberg.

- ApplyMapping – Un objet [ApplyMapping](#).

Indique une transformation qui mappe les clés de propriétés de données de la source de données aux clés de propriété de données de la cible de données. Vous pouvez renommer les clés, modifier leur type de données et choisir les clés à supprimer du jeu de données.

- SelectFields – Un objet [SelectFields](#).

Indique une transformation qui choisit les clés de propriété de données que vous souhaitez conserver.

- DropFields – Un objet [DropFields](#).

Indique une transformation qui choisit les clés de propriété de données que vous souhaitez supprimer.

- `RenameField` – Un objet [RenameField](#).

Indique une transformation qui renomme une clé de propriété de données unique.

- `Spigot` – Un objet [Spigot](#).

Indique une transformation qui écrit des échantillons de données dans un compartiment Amazon S3.

- `Join` – Un objet [Join](#).

Indique une transformation qui joint deux jeux de données en un jeu de données à l'aide d'une phrase de comparaison sur les clés de propriété de données spécifiées. Vous pouvez utiliser des jointures internes (ou intérieures), externes (ou extérieures), gauche, droite, semi gauche et anti gauche.

- `SplitFields` – Un objet [SplitFields](#).

Indique une transformation qui divise les clés de propriété de données en deux `DynamicFrames`. Le résultat est une collection de `DynamicFrames` : une avec les clés de propriété de données sélectionnées, et une autre avec les clés de propriété de données restantes.

- `SelectFromCollection` – Un objet [SelectFromCollection](#).

Indique une transformation qui en choisit une `DynamicFrame` provenant d'une collection de `DynamicFrames`. Le résultat est le `DynamicFrame` sélectionné

- `FillMissingValues` – Un objet [FillMissingValues](#).

Indique une transformation qui localise les registres dans le jeu de données dont les valeurs sont manquantes et ajoute un nouveau champ avec une valeur déterminée par imputation. Le jeu de données source est utilisé pour entraîner le modèle de machine learning (ML) qui détermine la valeur manquante.

- `Filter` – Un objet [Filtre](#).

Indique une transformation qui divise un jeu de données en deux, en fonction d'une condition de filtre.

- `CustomCode` – Un objet [CustomCode](#).

Indique une transformation qui utilise le code personnalisé que vous fournissez pour effectuer la transformation des données. La sortie est une collection de `DynamicFrames`.

- `SparkSQL` – Un objet [SparkSQL](#).

Indique une transformation dans laquelle vous entrez une requête SQL à l'aide de la syntaxe Spark SQL pour transformer les données. Le résultat est un `DynamicFrame` unique.

- `DirectKinesisSource` – Un objet [DirectKinesisSource](#).

Indique une source de données Amazon Kinesis directe.

- `DirectKafkaSource` – Un objet [DirectKafkaSource](#).

Indique un stocker de données Apache Kafka.

- `CatalogKinesisSource` – Un objet [CatalogKinesisSource](#).

Spécifie une source de données Kinesis dans le catalogue de AWS Glue données.

- `CatalogKafkaSource` – Un objet [CatalogKafkaSource](#).

Indique un stocker de données Apache Kafka dans le catalogue de données.

- `DropNullFields` – Un objet [DropNullFields](#).

Indique une transformation qui supprime les colonnes du jeu de données si toutes les valeurs de la colonne sont « nulles ». Par défaut, AWS Glue Studio reconnaît les objets nuls, mais certaines valeurs telles que les chaînes vides, les chaînes « nulles », les entiers -1 ou d'autres espaces réservés tels que les zéros ne sont pas automatiquement reconnues comme nulles.

- `Merge` – Un objet [Fusionner](#).

Indique une transformation qui fusionne une `DynamicFrame` avec une `DynamicFrame` intermédiaire basée sur les clés primaires spécifiées pour identifier les registres. Les registres en double (registres avec les mêmes clés primaires) ne sont pas dédupliqués.

- `Union` – Un objet [Union](#).

Indique une transformation qui combine les lignes de deux jeux de données ou plus en un seul résultat.

- `PIIDetection` – Un objet [PIIDetection](#).

Indique une transformation qui identifie, supprime ou masque les données d'informations personnelles identifiables (PII).

- `Aggregate` – Un objet [Regrouper](#).

Indique une transformation qui regroupe les lignes par champs choisis et calcule la valeur agrégée par fonction spécifiée.

- DropDuplicates – Un objet [DropDuplicates](#).

Indique une transformation qui supprime des lignes de données répétitives d'un jeu de données.

- GovernedCatalogTarget – Un objet [GovernedCatalogTarget](#).

Indique une cible de données qui écrit dans un catalogue gouverné.

- GovernedCatalogSource – Un objet [GovernedCatalogSource](#).

Indique une source de données dans un catalogue de données gouverné.

- MicrosoftSQLServerCatalogSource – Un objet [Microsoft SQL Server CatalogSource](#).

Indique une source de données Microsoft SQL Server dans le catalogue de données AWS Glue .

- MySQLCatalogSource – Un objet [Ma SQLCatalog source](#).

Spécifie une source de données MySQL dans le catalogue de AWS Glue données.

- OracleSQLCatalogSource – Un objet [SQLCatalogSource d'Oracle](#).

Spécifie une source de données Oracle dans le catalogue de AWS Glue données.

- PostgreSQLCatalogSource – Un objet [Source de Postgrer SQLCatalog](#).

Spécifie une source de données PostgreSQL dans le catalogue de données. AWS Glue

- MicrosoftSQLServerCatalogTarget – Un objet [Microsoft SQL Server CatalogTarget](#).

Indique une cible qui utilise Microsoft SQL.

- MySQLCatalogTarget – Un objet [Ma SQLCatalog cible](#).

Indique une cible qui utilise MySQL.

- OracleSQLCatalogTarget – Un objet [SQLCatalogCible Oracle](#).

Indique une cible qui utilise Oracle SQL.

- PostgreSQLCatalogTarget – Un objet [Cible Postgrer SQLCatalog](#).

Indique une cible qui utilise Postgre SQL.

- DynamicTransform – Un objet [DynamicTransform](#).

Spécifie une transformation visuelle personnalisée créée par un utilisateur.

- ~~EvaluatedDataQuality~~ – Un objet [EvaluatedDataQuality](#).

Spécifie vos critères d'évaluation de la qualité des données.

- S3CatalogHudiSource – Un objet [S3 CatalogHudiSource](#).

Spécifie une source de données Hudi enregistrée dans le catalogue de AWS Glue données. La source de données doit être stockée dans Amazon S3.

- CatalogHudiSource – Un objet [CatalogHudiSource](#).

Spécifie une source de données Hudi enregistrée dans le catalogue de AWS Glue données.

- S3HudiSource – Un objet [S3 HudiSource](#).

Spécifie une source de données Hudi stockée dans. Amazon S3

- S3HudiCatalogTarget – Un objet [S3 HudiCatalogTarget](#).

Spécifie une cible qui écrit dans une source de données Hudi du catalogue de AWS Glue données.

- S3HudiDirectTarget – Un objet [S3 HudiDirectTarget](#).

Spécifie une cible qui écrit dans une source de données Hudi en Amazon S3.

- S3CatalogDeltaSource – Un objet [S3 CatalogDeltaSource](#).

Spécifie une source de données Delta Lake enregistrée dans le catalogue de AWS Glue données. La source de données doit être stockée dans Amazon S3.

- CatalogDeltaSource – Un objet [CatalogDeltaSource](#).

Spécifie une source de données Delta Lake enregistrée dans le catalogue de AWS Glue données.

- S3DeltaSource – Un objet [S3 DeltaSource](#).

Spécifie une source de données Delta Lake stockée dans Amazon S3.

- S3DeltaCatalogTarget – Un objet [S3 DeltaCatalogTarget](#).

Spécifie une cible qui écrit dans une source de données Delta Lake dans le catalogue de AWS Glue données.

- S3DeltaDirectTarget – Un objet [S3 DeltaDirectTarget](#).

Spécifie une cible qui écrit dans une source de données de Delta Lake en Amazon S3.

- AmazonRedshiftSource – Un objet [AmazonRedshiftSource](#).

Indique une cible qui écrit dans une source de données dans Amazon Redshift.

- AmazonRedshiftTarget – Un objet [AmazonRedshiftTarget](#).

Indique une cible qui écrit dans une cible de données dans Amazon Redshift.

- EvaluateDataQualityMultiFrame – Un objet [EvaluateDataQualityMultiFrame](#).

Spécifie vos critères d'évaluation de la qualité des données. Autorise plusieurs données d'entrée et renvoie une collection de cadres dynamiques.

- Recipe – Un objet [Recipe](#).

Spécifie un nœud de AWS Glue DataBrew recette.

- SnowflakeSource – Un objet [SnowflakeSource](#).

Indique une source de données Snowflake.

- SnowflakeTarget – Un objet [SnowflakeTarget](#).

Indique une cible qui écrit dans une source de données Snowflake.

- ConnectorDataSource – Un objet [ConnectorDataSource](#).

Spécifie une source générée avec des options de connexion standard.

- ConnectorDataTarget – Un objet [ConnectorDataTarget](#).

Spécifie une cible générée avec des options de connexion standard.

JDBCConectorStructure des options

Options de connexion supplémentaires pour le connecteur.

Champs

- FilterPredicate – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Clause de condition supplémentaire pour filtrer les données à partir de la source. Par exemple :

```
BillingCity='Mountain View'
```

Lorsque vous utilisez une requête au lieu d'un nom de tableau, vous devez vérifier que la requête fonctionne avec le filterPredicate spécifié.

- PartitionColumn – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom d'une colonne entière utilisée pour le partitionnement. Cette option fonctionne uniquement lorsqu'elle est incluse dans `lowerBound`, `upperBound` et `numPartitions`. Cette option fonctionne de la même manière que dans le lecteur JDBC SQL Spark.

- `LowerBound` – Nombre (long), pas plus qu'Aucun.

La valeur minimale de `partitionColumn` qui est utilisée pour décider de la progression de la partition.

- `UpperBound` – Nombre (long), pas plus qu'Aucun.

La valeur maximale de `partitionColumn` qui est utilisée pour décider de la progression de la partition.

- `NumPartitions` – Nombre (long), pas plus qu'Aucun.

Nombre de partitions. Cette valeur, ainsi que `lowerBound` (inclusive) et `upperBound` (exclusive) forment les progressions de partition pour les expressions de clause WHERE générées qui sont utilisées pour diviser le fichier `partitionColumn`.

- `JobBookmarkKeys` – Tableau de chaînes UTF-8.

Le nom des clés de marque-page de tâches sur lesquelles effectuer le tri.

- `JobBookmarkKeysSortOrder` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique un ordre de tri croissant ou décroissant.

- `DataTypeMapping` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8 (valeurs valides : `ARRAY` | `BIGINT` | `BINARY` | `BIT` | `BLOB` | `BOOLEAN` | `CHAR` | `CLOB` | `DATALINK` | `DATE` | `DECIMAL` | `DISTINCT` | `DOUBLE` | `FLOAT` | `INTEGER` | `JAVA_OBJECT` | `LONGNVARCHAR` | `LONGVARBINARY` | `LONGVARCHAR` | `NCHAR` | `NCLOB` | `NULL` | `NUMERIC` | `NVARCHAR` | `OTHER` | `REAL` | `REF` | `REF_CURSOR` | `ROWID` | `SMALLINT` | `SQLXML` | `STRUCT` | `TIME` | `TIME_WITH_TIMEZONE` | `TIMESTAMP` | `TIMESTAMP_WITH_TIMEZONE` | `TINYINT` | `VARBINARY` | `VARCHAR`).

Chaque valeur est une chaîne UTF-8 (valeurs valides : `DATE` | `STRING` | `TIMESTAMP` | `INT` | `FLOAT` | `LONG` | `BIGDECIMAL` | `BYTE` | `SHORT` | `DOUBLE`).

Mappage de type de données personnalisé qui crée un mappage d'un type de données JDBC à un type de données AWS Glue . Par exemple, l'option `"dataTypeMapping"` : `{"FLOAT": "STRING"}` mappe les champs de données de type JDBC `FLOAT` dans le `String`

type Java en appelant la `ResultSet.getString()` méthode du pilote et l'utilise pour créer l'AWS Glue enregistrement. L'objet est `ResultSet` implémenté par chaque pilote, donc le comportement est spécifique au pilote que vous utilisez. Reportez-vous à la documentation de votre pilote JDBC pour comprendre comment le pilote effectue les conversions.

StreamingDataPreviewOptions structure

Indique les options liées à la prévisualisation des données pour visualiser un échantillon de vos données.

Champs

- `PollingTime` : nombre (long), au moins égal à 10.

Temps d'interrogation en millisecondes.

- `RecordPollingLimit` : nombre (long), au moins égal à 1.

Limite du nombre de registres interrogés.

AthenaConnectorSource structure

Indique un connecteur à une source de données Amazon Athena.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source de données.

- `ConnectionName` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la connexion associée au connecteur.

- `ConnectorName` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom d'un connecteur qui facilite l'accès au magasin de données dans AWS Glue Studio.

- `ConnectionType` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Type de connexion, tel que `marketplace.athena` ou `custom.athena`, désignant une connexion à un stocker de données Amazon Athena.

- `ConnectionTable` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la source de données.

- **SchemaName** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom du groupe de journaux CloudWatch à partir duquel lire les données. Par exemple, /aws-glue/jobs/output.

- **OutputSchemas** – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la source Athena personnalisée.

JDBCCConnectorStructure de la source

Indique un connecteur à une source de données JDBC.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source de données.

- **ConnectionName** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la connexion associée au connecteur.

- **ConnectorName** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom d'un connecteur qui facilite l'accès au magasin de données dans AWS Glue Studio.

- **ConnectionType** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Type de connexion, tel que marketplace.jdbc ou custom.jdbc, désignant une connexion à un stocker de données JDBC.

- **AdditionalOptions** – Un objet [JDBCCConnectorOptions](#).

Options de connexion supplémentaires pour le connecteur.

- **ConnectionTable** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la source de données.

- **Query** – Chaîne UTF-8, correspondant au [Custom string pattern #60](#).

La table ou la requête SQL à partir de laquelle obtenir les données. Vous pouvez préciser **ConnectionTable** ou **query**, mais pas les deux.

- `OutputSchemas` – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la source JDBC personnalisée.

SparkConnectorSource structure

Indique un connecteur à une source de données Apache Spark.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source de données.

- `ConnectionName` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la connexion associée au connecteur.

- `ConnectorName` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom d'un connecteur qui facilite l'accès au magasin de données dans AWS Glue Studio.

- `ConnectionType` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Type de connexion, tel que `marketplace.spark` ou `custom.spark`, désignant une connexion à un stocker de données Apache Spark.

- `AdditionalOptions` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Options de connexion supplémentaires pour le connecteur.

- `OutputSchemas` – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la source Spark personnalisée.

CatalogSource structure

Spécifie un magasin de données dans le catalogue de AWS Glue données.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).
Nom du stocker de données.
- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).
Le nom de la base de données à partir de laquelle lire les données.
- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).
Le nom de la table dans la base de données à partir de laquelle lire les données.

Structure SQLCatalog de ma source

Spécifie une source de données MySQL dans le catalogue de AWS Glue données.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).
Nom de la source de données.
- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).
Le nom de la base de données à partir de laquelle lire les données.
- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).
Le nom de la table dans la base de données à partir de laquelle lire les données.

Structure de la SQLCatalog source Postgre

Spécifie une source de données PostgreSQL dans le catalogue de données. AWS Glue

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).
Nom de la source de données.
- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).
Le nom de la base de données à partir de laquelle lire les données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la base de données à partir de laquelle lire les données.

Structure d'Oracle SQLCatalog Source

Spécifie une source de données Oracle dans le catalogue de AWS Glue données.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source de données.

- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données à partir de laquelle lire les données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la base de données à partir de laquelle lire les données.

SQLServerCatalogSource Structure de Microsoft

Indique une source de données Microsoft SQL Server dans le catalogue de données AWS Glue .

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source de données.

- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données à partir de laquelle lire les données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la base de données à partir de laquelle lire les données.

CatalogKinesisSource structure

Spécifie une source de données Kinesis dans le catalogue de AWS Glue données.

Champs

- Name – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source de données.

- WindowSize – Nombre (entier), pas plus qu'Aucun.

Durée de traitement de chaque micro lot.

- DetectSchema – Booléen.

Indique s'il faut déterminer automatiquement le schéma à partir des données entrantes.

- Table – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la base de données à partir de laquelle lire les données.

- Database – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données à partir de laquelle lire les données.

- StreamingOptions – Un objet [KinesisStreamingSourceOptions](#).

Options supplémentaires pour la source de données en streaming Kinesis.

- DataPreviewOptions – Un objet [StreamingDataPreviewOptions](#).

Options supplémentaires pour la prévisualisation des données.

DirectKinesisSource structure

Indique une source de données Amazon Kinesis directe.

Champs

- Name – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source de données.

- WindowSize – Nombre (entier), pas plus qu'Aucun.

Durée de traitement de chaque micro lot.

- DetectSchema – Booléen.

Indique s'il faut déterminer automatiquement le schéma à partir des données entrantes.

- `StreamingOptions` – Un objet [KinesisStreamingSourceOptions](#).

Options supplémentaires pour la source de données en streaming Kinesis.

- `DataPreviewOptions` – Un objet [StreamingDataPreviewOptions](#).

Options supplémentaires pour la prévisualisation des données.

KinesisStreamingSourceOptions structure

Options supplémentaires pour la source de données Amazon Kinesis streaming.

Champs

- `EndpointUrl` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

L'URL du point de terminaison de Kinesis.

- `StreamName` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom du flux de données Kinesis.

- `Classification` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Une classification facultative.

- `Delimiter` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique le caractère délimiteur.

- `StartingPosition` – Chaîne UTF-8 (valeurs valides : `latest="LATEST"` | `trim_horizon="TRIM_HORIZON"` | `earliest="EARLIEST"` | `timestamp="TIMESTAMP"`).

La position de départ dans le flux de données Kinesis à partir duquel lire les données. Les valeurs possibles sont "latest", "trim_horizon", "earliest", ou une chaîne d'horodatage au format UTC dans le modèle yyyy-mm-ddTHH:MM:SSZ (où Z représente un décalage de fuseau horaire UTC avec un +/-). Par exemple : « 2023-04-04T08:00:00-04:00 ». La valeur par défaut est "latest".

Remarque : L'utilisation d'une valeur qui est une chaîne d'horodatage au format UTC pour « `StartingPosition` » n'est prise en charge que pour la AWS Glue version 4.0 ou ultérieure.

- `MaxFetchTimeInMs` – Nombre (long), pas plus qu'Aucun.

Durée maximale pendant laquelle l'exécuteur de tâches lit les enregistrements du lot en cours à partir du flux de données Kinesis, spécifiée en millisecondes (ms). Plusieurs appels `GetRecords` d'API peuvent être effectués pendant cette période. La valeur par défaut est 1000.

- `MaxFetchRecordsPerShard` – Nombre (long), pas plus qu'Aucun.

Le nombre maximum d'enregistrements à récupérer par partition dans le flux de données Kinesis par microbatch. Remarque : le client peut dépasser cette limite si la tâche de streaming a déjà lu des enregistrements supplémentaires provenant de Kinesis (lors du même appel `get-records`). Si elle `MaxFetchRecordsPerShard` doit être stricte, elle doit être un multiple de `MaxRecordPerRead`. La valeur par défaut est 100000.

- `MaxRecordPerRead` – Nombre (long), pas plus qu'Aucun.

Nombre maximal de registres à extraire du flux de données Kinesis dans chaque opération. La valeur par défaut est 10000.

- `AddIdleTimeBetweenReads` – Booléen.

Ajoute un délai entre deux opérations `getRecords` consécutives. La valeur par défaut est "False". Cette option n'est configurable que pour les AWS Glue versions 2.0 et supérieures.

- `IdleTimeBetweenReadsInMs` – Nombre (long), pas plus qu'Aucun.

Le délai minimum entre deux opérations `getRecords` consécutives, spécifié en ms. La valeur par défaut est 1000. Cette option n'est configurable que pour les AWS Glue versions 2.0 et supérieures.

- `DescribeShardInterval` – Nombre (long), pas plus qu'Aucun.

Intervalle de temps minimum entre deux appels `ListShards` d'API avant que votre script envisage le repartage. La valeur par défaut est 1s.

- `NumRetries` – Nombre (entier), pas plus qu'Aucun.

Le nombre maximal de nouvelles tentatives pour les demandes d'API Kinesis Data Streams. La valeur par défaut est 3.

- `RetryIntervalMs` – Nombre (long), pas plus qu'Aucun.

Le délai de réflexion (spécifié en ms) avant de réessayer l'appel d'API Kinesis Data Streams. La valeur par défaut est 1000.

- `MaxRetryIntervalMs` – Nombre (long), pas plus qu'Aucun.

Le délai d'attente maximal (spécifié en ms) entre deux tentatives d'appel d'API Kinesis Data Streams. La valeur par défaut est 10000.

- `AvoidEmptyBatches` – Booléen.

Évite de créer une tâche de micro-lot vide en vérifiant les données non lues dans le flux de données Kinesis avant le démarrage du lot. La valeur par défaut est "False".

- `StreamArn` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom Amazon Resource Name (ARN) du flux de données Kinesis.

- `RoleArn` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom Amazon Resource Name (ARN) du rôle à endosser à l'aide d'AWS Security Token Service (AWS STS). Ce rôle doit disposer des autorisations nécessaires pour écrire ou lire des registres pour le flux de données Kinesis. Vous devez utiliser ce paramètre lorsque vous accédez à un flux de données dans un autre compte. Utilisez conjointement avec "awsSTSSessionName".

- `RoleSessionName` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Un identifiant de la session endossant le rôle à l'aide d'AWS STS. Vous devez utiliser ce paramètre lorsque vous accédez à un flux de données dans un autre compte. Utilisez conjointement avec "awsSTSRoleARN".

- `AddRecordTimestamp` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Lorsque cette option est définie sur « true », la sortie de données contient une colonne supplémentaire nommée « `__src_timestamp` » qui indique l'heure à laquelle l'enregistrement correspondant est reçu par le flux. La valeur par défaut est « false ». Cette option est prise en charge dans AWS Glue la version 4.0 ou ultérieure.

- `EmitConsumerLagMetrics` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Lorsque cette option est définie sur « true », pour chaque lot, elle émet les métriques correspondant à la durée comprise entre le plus ancien enregistrement reçu par le flux et l'heure AWS Glue à laquelle il arrive CloudWatch. Le nom de la métrique est « `glue.driver.streaming.maxConsumerLagInMs` ». La valeur par défaut est « false ». Cette option est prise en charge dans AWS Glue version 4.0 ou ultérieure.

- `StartingTimestamp` – Chaîne UTF-8.

L'horodatage de l'enregistrement dans le flux de données Kinesis à partir duquel les données doivent être lues. Les valeurs possibles sont une chaîne d'horodatage au format UTC du modèle

yyyy-mm-ddTHH:MM:SSZ (où Z représente un décalage de fuseau horaire UTC avec un +/-). Par exemple : « 2023-04-04T08:00:00+08:00 »).

CatalogKafkaSource structure

Indique un stocker de données Apache Kafka dans le catalogue de données.

Champs

- Name – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du stocker de données.

- WindowSize – Nombre (entier), pas plus qu'Aucun.

Durée de traitement de chaque micro lot.

- DetectSchema – Booléen.

Indique s'il faut déterminer automatiquement le schéma à partir des données entrantes.

- Table – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la base de données à partir de laquelle lire les données.

- Database – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données à partir de laquelle lire les données.

- StreamingOptions – Un objet [KafkaStreamingSourceOptions](#).

Indique les options de streaming.

- DataPreviewOptions – Un objet [StreamingDataPreviewOptions](#).

Indique les options liées à la prévisualisation des données pour visualiser un échantillon de vos données.

DirectKafkaSource structure

Indique un stocker de données Apache Kafka.

Champs

- Name – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du stocker de données.

- `StreamingOptions` – Un objet [KafkaStreamingSourceOptions](#).

Indique les options de streaming.

- `WindowSize` – Nombre (entier), pas plus qu'Aucun.

Durée de traitement de chaque micro lot.

- `DetectSchema` – Booléen.

Indique s'il faut déterminer automatiquement le schéma à partir des données entrantes.

- `DataPreviewOptions` – Un objet [StreamingDataPreviewOptions](#).

Indique les options liées à la prévisualisation des données pour visualiser un échantillon de vos données.

KafkaStreamingSourceOptions structure

Options supplémentaires pour streaming.

Champs

- `BootstrapServers` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Une liste de serveurs bootstrap URLs, par exemple, comme `b-1.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094`. Cette option doit être spécifiée dans l'appel d'API ou définie dans les métadonnées de la table dans le catalogue de données.

- `SecurityProtocol` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le protocole utilisé pour communiquer avec les agents. Les valeurs possibles sont "SSL" ou "PLAINTEXT".

- `ConnectionName` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Nom de la connexion.

- `TopicName` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de rubrique tel que spécifié dans Apache Kafka. Vous devez indiquer au moins un des éléments suivants : "topicName", "assign" ou "subscribePattern".

- **Assign** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Les TopicPartitions spécifiques à consommer. Vous devez Indiquer au moins un des éléments suivants : "topicName", "assign" ou "subscribePattern".

- **SubscribePattern** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Une chaîne d'expression rationnelle Java qui identifie la liste de rubriques à laquelle vous souhaitez vous abonner. Vous devez Indiquer au moins un des éléments suivants : "topicName", "assign" ou "subscribePattern".

- **Classification** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Une classification facultative.

- **Delimiter** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique le caractère délimiteur.

- **StartingOffsets** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

La position de départ dans la rubrique Kafka à partir de laquelle lire les données. Les valeurs possibles sont "earliest" ou "latest". La valeur par défaut est "latest".

- **EndingOffsets** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le point de fin lorsqu'une requête par lots est terminée. Les valeurs possibles sont "latest" ou une chaîne JSON qui Indique un décalage de fin pour chaque TopicPartition.

- **PollTimeoutMs** – Nombre (long), pas plus qu'Aucun.

Le délai d'attente en millisecondes pour interroger les données de Kafka dans les exécuteurs de tâches Spark. La valeur par défaut est 512.

- **NumRetries** – Nombre (entier), pas plus qu'Aucun.

Le nombre de nouvelles tentatives avant de ne pas récupérer les décalages Kafka. La valeur par défaut est 3.

- **RetryIntervalMs** – Nombre (long), pas plus qu'Aucun.

Temps d'attente en millisecondes avant d'essayer de récupérer les décalages Kafka. La valeur par défaut est 10.

- **MaxOffsetsPerTrigger** – Nombre (long), pas plus qu'Aucun.

La limite de taux sur le nombre maximal de décalages qui sont traités par intervalle de déclenchement. Le nombre total spécifié de décalages est réparti proportionnellement entre les `topicPartitions` des différents volumes. La valeur par défaut est null, ce qui signifie que le consommateur lit tous les décalages jusqu'au dernier décalage connu.

- `MinPartitions` – Nombre (entier), pas plus qu'Aucun.

Le nombre minimum de partitions à lire à partir de Kafka. La valeur par défaut est nulle, ce qui signifie que le nombre de partitions Spark est égal au nombre de partitions Kafka.

- `IncludeHeaders` – Booléen.

Indique s'il faut inclure les en-têtes Kafka. Lorsque l'option est définie sur « true » (vrai), la sortie de données contiendra une colonne supplémentaire nommée « `glue_streaming_kafka_headers` » avec le type `Array[Struct(key: String, value: String)]`. La valeur définie par défaut est « false ». Cette option n'est disponible que dans AWS Glue la version 3.0 ou ultérieure.

- `AddRecordTimestamp` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Lorsque cette option est définie sur « true », la sortie de données contient une colonne supplémentaire nommée « `__src_timestamp` » qui indique l'heure à laquelle l'enregistrement correspondant est reçu par la rubrique. La valeur par défaut est « false ». Cette option est prise en charge dans AWS Glue la version 4.0 ou ultérieure.

- `EmitConsumerLagMetrics` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Lorsque cette option est définie sur « vrai », pour chaque lot, elle émet les métriques correspondant à la durée comprise entre le plus ancien enregistrement reçu par le sujet et l'heure AWS Glue à laquelle il arrive CloudWatch. Le nom de la métrique est « `glue.driver.streaming.maxConsumerLagInMs` ». La valeur par défaut est « false ». Cette option est prise en charge dans AWS Glue version 4.0 ou ultérieure.

- `StartingTimestamp` – Chaîne UTF-8.

L'horodatage de l'enregistrement dans la rubrique Kafka à partir duquel les données doivent être lues. Les valeurs possibles sont une chaîne d'horodatage au format UTC du modèle `yyyy-mm-ddTHH:MM:SSZ` (où Z représente un décalage de fuseau horaire UTC avec un +/-). Par exemple : « `2023-04-04T08:00:00+08:00` »).

Seul `StartingTimestamp` ou `StartingOffsets` doit être défini.

RedshiftSource structure

Indique un stocker de données Amazon Redshift.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom du stocker de données Amazon Redshift.

- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

La base de données à partir de laquelle lire les données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Table de base de données à lire.

- **RedshiftTmpDir** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chemin Amazon S3 où les données temporaires peuvent être stockées lors de la copie à partir de la base de données.

- **TmpDirIAMRole** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le rôle IAM avec les autorisations.

AmazonRedshiftSource structure

Indique une source Amazon Redshift.

Champs

- **Name** – Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la source Amazon Redshift.

- **Data** – Un objet [AmazonRedshiftNodeData](#).

Indique les données du nœud source Amazon Reshift.

AmazonRedshiftNodeData structure

Indique un nœud Amazon Redshift.

Champs

- **AccessType** – Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Le type d'accès pour la connexion Redshift. Il peut s'agir d'une connexion directe ou de connexions au catalogue.

- **SourceType** – Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Le type de source pour spécifier si une table spécifique est la source ou une requête personnalisée.

- **Connection** – Un objet [Option](#).

La AWS Glue connexion au cluster Redshift.

- **Schema** – Un objet [Option](#).

Le nom du schéma Redshift lorsque vous travaillez avec une connexion directe.

- **Table** – Un objet [Option](#).

Le nom de la table Redshift lorsque vous travaillez avec une connexion directe.

- **CatalogDatabase** – Un objet [Option](#).

Nom de la base de AWS Glue données du catalogue de données lorsque vous travaillez avec un catalogue de données.

- **CatalogTable** – Un objet [Option](#).

Le nom de la table du catalogue de AWS Glue données lorsque vous travaillez avec un catalogue de données.

- **CatalogRedshiftSchema** – Chaîne UTF-8.

Le nom du schéma Redshift lorsque vous travaillez avec un catalogue de données.

- **CatalogRedshiftTable** – Chaîne UTF-8.

Table de base de données à lire.

- **TempDir** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chemin Amazon S3 où les données temporaires peuvent être stockées lors de la copie à partir de la base de données.

- **IamRole** – Un objet [Option](#).

Facultatif. Le nom de rôle utilisé lors de la connexion à S3. Le rôle IAM sera remplacé par défaut par le rôle sur la tâche lorsque ce champ est laissé vide.

- `AdvancedOptions` – Un tableau d'objets [AmazonRedshiftAdvancedOption](#).

Les valeurs facultatives lors de la connexion au cluster Redshift.

- `SampleQuery` – Chaîne UTF-8.

Le code SQL utilisé pour récupérer les données d'une source Redshift lorsqu'il `SourceType` s'agit d'une « requête ».

- `PreAction` – Chaîne UTF-8.

Le code SQL utilisé avant l'exécution d'une opération `MERGE` ou `APPEND` avec insertion.

- `PostAction` – Chaîne UTF-8.

Le code SQL utilisé avant l'exécution d'une opération `MERGE` ou `APPEND` avec insertion.

- `Action` – Chaîne UTF-8.

Indique comment l'écriture dans un cluster Redshift se fera.

- `TablePrefix` – Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Indique le préfixe d'une table.

- `Upsert` – Booléen.

L'action utilisée sur les récepteurs Redshift lorsque vous effectuez une opération `APPEND`.

- `MergeAction` – Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

L'action utilisée pour déterminer comment une opération `MERGE` dans un récepteur Redshift sera traitée.

- `MergeWhenMatched` – Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

L'action utilisée pour déterminer comment une opération `MERGE` dans un récepteur Redshift sera traitée lorsqu'un enregistrement existant correspond à un nouvel enregistrement.

- `MergeWhenNotMatched` – Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

L'action utilisée pour déterminer comment une opération `MERGE` dans un récepteur Redshift sera traitée lorsqu'un enregistrement existant ne correspond pas à un nouvel enregistrement.

- `MergeClause` – Chaîne UTF-8.

Le code SQL utilisé dans une fusion personnalisée pour traiter les enregistrements correspondants.

- `CrawlerConnection` – Chaîne UTF-8.

Indique le nom de la connexion associée à la table de catalogue utilisée.

- `TableSchema` – Un tableau d'objets [Option](#).

Le tableau de sortie du schéma pour un nœud donné.

- `StagingTable` – Chaîne UTF-8.

Le nom de la table intermédiaire temporaire utilisée lors d'une opération MERGE ou APPEND avec insertion.

- `SelectedColumns` – Un tableau d'objets [Option](#).

La liste des noms de colonnes utilisée pour déterminer un enregistrement correspondant lors d'une opération MERGE ou APPEND avec insertion.

AmazonRedshiftAdvancedOption structure

Indique une valeur facultative lors de la connexion au cluster Redshift.

Champs

- `Key` – Chaîne UTF-8.

La clé de l'option de connexion supplémentaire.

- `Value` – Chaîne UTF-8.

La valeur de l'option de connexion supplémentaire.

Structure de l'option

Indique une valeur d'option.

Champs

- `Value` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique la valeur de l'option.

- `Label` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique l'étiquette de l'option.

- `Description` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique la description de l'option.

CatalogSource Structure S3

Spécifie un magasin de données Amazon S3 dans le catalogue de AWS Glue données.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du stocker de données.

- `Database` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

La base de données à partir de laquelle lire les données.

- `Table` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Table de base de données à lire.

- `PartitionPredicate` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Les partitions satisfaisant à ce prédicat sont supprimées. Les fichiers qui se situent dans la période de conservation pour ces partitions ne sont pas supprimés. Valeur définie sur "" – vide par défaut.

- `AdditionalOptions` – Un objet [S3 SourceAdditionalOptions](#).

Indique des options de connexion supplémentaires.

SourceAdditionalOptions Structure S3

Indique des options de connexion supplémentaires pour le stocker de données Amazon S3.

Champs

- `BoundedSize` – Nombre (long).

Définit la limite supérieure de la dimension cible du jeu de données en octets à traiter.

- `BoundedFiles` – Nombre (long).

Définit la limite supérieure du nombre cible de fichiers à traiter.

CsvSource Structure S3

Indique un stocker de données CSV (valeurs séparées par commande) stocké dans Amazon S3.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du stocker de données.

- `Paths` – Obligatoire : Tableau de chaînes UTF-8.

Une liste de chemins Amazon S3 à lire.

- `CompressionType` – Chaîne UTF-8 (valeurs valides : `gzip="GZIP" | bzip2="BZIP2"`).

Indique la manière dont les données sont comprimées. Ce n'est généralement pas nécessaire si le fichier de données a une extension standard. Les valeurs possibles sont `"gzip"` et `"bzip"`.

- `Exclusions` – Tableau de chaînes UTF-8.

Une chaîne contenant une liste JSON des modèles glob de style Unix à exclure. Par exemple, `[\"**/*.pdf\"]` permet d'exclure tous les fichiers PDF.

- `GroupSize` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

La dimension du groupe cible, en octets. La valeur par défaut est calculée en fonction de la dimension des données en entrée et de la dimension de votre cluster. Lorsqu'il y a moins de 50 000 fichiers en entrée, `"groupFiles"` doit être défini sur `"inPartition"` pour que cela prenne effet.

- `GroupFiles` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le groupement de fichiers est activé par défaut lorsque l'entrée contient plus de 50 000 fichiers. Pour activer le groupement lorsqu'il y a moins de 50 000 fichiers, définissez ce paramètre sur « `inPartition` ». Pour désactiver le groupement lorsqu'il y a plus de 50 000 fichiers, définissez ce paramètre sur `"none"`.

- `Recurse` – Booléen.

Si ce paramètre est défini sur « VRAI », les fichiers sont lus de manière récursive dans tous les sous-répertoires des chemins spécifiés.

- `MaxBand` – Nombre (entier), pas plus qu'Aucun.

Cette option permet de contrôler la durée, en millisecondes, au delà de laquelle la liste S3 est susceptible d'être cohérente. Les fichiers dont l'horodatage des modifications se situe dans les dernières millisecondes de `MaxBand` sont suivis, en particulier lors de leur utilisation, afin de tenir compte de la cohérence éventuelle JobBookmarks d'Amazon S3. La plupart des utilisateurs n'ont pas besoin de définir cette option. La valeur par défaut est 900 000 millisecondes, soit 15 minutes.

- `MaxFilesInBand` – Nombre (entier), pas plus qu'Aucun.

Cette option Indique le nombre maximal de fichiers à enregistrer à partir des dernières secondes `maxBand`. Si ce nombre est dépassé, les fichiers supplémentaires sont ignorés et traités dans l'exécution de tâche suivante.

- `AdditionalOptions` – Un objet [S3 DirectSourceAdditionalOptions](#).

Indique des options de connexion supplémentaires.

- `Separator` – Obligatoire : Chaîne UTF-8 (valeurs valides : `comma="COMMA"` | `ctrla="CTRLA"` | `pipe="PIPE"` | `semicolon="SEMICOLON"` | `tab="TAB"`).

Indique le caractère délimiteur. La valeur par défaut est une virgule : « , », mais tout autre caractère peut être spécifié.

- `Escaper` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique le caractère à utiliser pour l'échappement. Cette option est utilisée uniquement lors de la lecture de fichiers CSV. La valeur par défaut est none. Si cette option est activée, le caractère suivant est immédiatement utilisé tel quel, sauf pour un petit ensemble d'échappements connus (`\n`, `\r`, `\t` et `\0`).

- `QuoteChar` – Obligatoire : Chaîne UTF-8 (valeurs valides : `quote="QUOTE"` | `quillet="QUILLET"` | `single_quote="SINGLE_QUOTE"` | `disabled="DISABLED"`).

Indique le caractère à utiliser pour les guillemets. La valeur par défaut est les guillemets doubles : ' '. Définissez ce champ sur -1 pour désactiver entièrement les guillemets.

- `Multiline` – Booléen.

Une valeur booléenne qui indique si un même registre peut couvrir plusieurs lignes. Cela peut se produire lorsqu'un champ contient un caractère de nouvelle ligne. Vous devez définir cette option sur « VRAI » si aucun registre ne s'étend sur plusieurs lignes. La valeur par défaut est `False`, qui permet un fractionnement en fichiers plus intense pendant l'analyse.

- `WithHeader` – Booléen.

Une valeur booléenne qui indique s'il convient de traiter la première ligne comme un en-tête. La valeur par défaut est `False`.

- `WriteHeader` – Booléen.

Une valeur booléenne qui indique s'il faut écrire l'en-tête dans la sortie. La valeur par défaut est `True`.

- `SkipFirst` – Booléen.

Une valeur booléenne qui indique s'il faut ignorer la première ligne de données. La valeur par défaut est `False`.

- `OptimizePerformance` – Booléen.

Une valeur booléenne qui indique s'il faut utiliser le lecteur CSV SIMD avancé avec les formats de mémoire en colonnes basés sur Apache Arrow. Disponible uniquement dans AWS Glue la version 3.0.

- `OutputSchemas` – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la source S3 CSV.

JDBCSource Structure directe

Indique la connexion directe à la source JDBC.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la connexion à la source JDBC.

- `Database` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Base de données de la connexion à la source JDBC.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Table de la connexion à la source JDBC.

- **ConnectionName** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Nom de connexion de la source JDBC.

- **ConnectionType** – Obligatoire : Chaîne UTF-8 (valeurs valides : `sqlserver` | `mysql` | `oracle` | `postgresql` | `redshift`).

Type de connexion de la source JDBC.

- **RedshiftTmpDir** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Répertoire temporaire de la source JDBC Redshift.

DirectSourceAdditionalOptions Structure S3

Indique des options de connexion supplémentaires pour le stocker de données Amazon S3.

Champs

- **BoundedSize** – Nombre (long).

Définit la limite supérieure de la dimension cible du jeu de données en octets à traiter.

- **BoundedFiles** – Nombre (long).

Définit la limite supérieure du nombre cible de fichiers à traiter.

- **EnableSamplePath** – Booléen.

Définit l'option d'activation d'un exemple de chemin.

- **SamplePath** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Si cette option est activée, elle indique l'exemple de chemin.

JsonSource Structure S3

Indique un stocker de données JSON stocké dans Amazon S3.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du stocker de données.

- **Paths** – Obligatoire : Tableau de chaînes UTF-8.

Une liste de chemins Amazon S3 à lire.

- **CompressionType** – Chaîne UTF-8 (valeurs valides : `gzip="GZIP" | bzip2="BZIP2"`).

Indique la manière dont les données sont comprimées. Ce n'est généralement pas nécessaire si le fichier de données a une extension standard. Les valeurs possibles sont `"gzip"` et `"bzip"`.

- **Exclusions** – Tableau de chaînes UTF-8.

Une chaîne contenant une liste JSON des modèles glob de style Unix à exclure. Par exemple, `[\"**.*pdf\"]` permet d'exclure tous les fichiers PDF.

- **GroupSize** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

La dimension du groupe cible, en octets. La valeur par défaut est calculée en fonction de la dimension des données en entrée et de la dimension de votre cluster. Lorsqu'il y a moins de 50 000 fichiers en entrée, `"groupFiles"` doit être défini sur `"inPartition"` pour que cela prenne effet.

- **GroupFiles** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le groupement de fichiers est activé par défaut lorsque l'entrée contient plus de 50 000 fichiers. Pour activer le groupement lorsqu'il y a moins de 50 000 fichiers, définissez ce paramètre sur « `inPartition` ». Pour désactiver le groupement lorsqu'il y a plus de 50 000 fichiers, définissez ce paramètre sur `"none"`.

- **Recurse** – Booléen.

Si ce paramètre est défini sur « `VRAI` », les fichiers sont lus de manière récursive dans tous les sous-répertoires des chemins spécifiés.

- **MaxBand** – Nombre (entier), pas plus qu'Aucun.

Cette option permet de contrôler la durée, en millisecondes, au delà de laquelle la liste S3 est susceptible d'être cohérente. Les fichiers dont l'horodatage des modifications se situe dans les dernières millisecondes de `MaxBand` sont suivis, en particulier lors de leur utilisation, afin de tenir

compte de la cohérence éventuelle JobBookmarks d'Amazon S3. La plupart des utilisateurs n'ont pas besoin de définir cette option. La valeur par défaut est 900 000 millisecondes, soit 15 minutes.

- `MaxFilesInBand` – Nombre (entier), pas plus qu'Aucun.

Cette option Indique le nombre maximal de fichiers à enregistrer à partir des dernières secondes `maxBand`. Si ce nombre est dépassé, les fichiers supplémentaires sont ignorés et traités dans l'exécution de tâche suivante.

- `AdditionalOptions` – Un objet [S3 DirectSourceAdditionalOptions](#).

Indique des options de connexion supplémentaires.

- `JsonPath` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

JsonPath Chaîne définissant les données JSON.

- `Multiline` – Booléen.

Une valeur booléenne qui indique si un même registre peut couvrir plusieurs lignes. Cela peut se produire lorsqu'un champ contient un caractère de nouvelle ligne. Vous devez définir cette option sur « VRAI » si aucun registre ne s'étend sur plusieurs lignes. La valeur par défaut est `False`, qui permet un fractionnement en fichiers plus intense pendant l'analyse.

- `OutputSchemas` – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la source S3 JSON.

ParquetSource Structure S3

Indique un stocker de données Apache Parquet stocké dans Amazon S3.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du stocker de données.

- `Paths` – Obligatoire : Tableau de chaînes UTF-8.

Une liste de chemins Amazon S3 à lire.

- `CompressionType` – Chaîne UTF-8 (valeurs valides: `snappy="SNAPPY"` | `lzo="LZO"` | `gzip="GZIP"` | `brotli="BROTLI"` | `lz4="LZ4"` | `uncompressed="UNCOMPRESSED"` | `none="NONE"`).

Indique la manière dont les données sont comprimées. Ce n'est généralement pas nécessaire si le fichier de données a une extension standard. Les valeurs possibles sont "gzip" et "bzip").

- **Exclusions** – Tableau de chaînes UTF-8.

Une chaîne contenant une liste JSON des modèles glob de style Unix à exclure. Par exemple, ["**/*.pdf"] permet d'exclure tous les fichiers PDF.

- **GroupSize** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

La dimension du groupe cible, en octets. La valeur par défaut est calculée en fonction de la dimension des données en entrée et de la dimension de votre cluster. Lorsqu'il y a moins de 50 000 fichiers en entrée, "groupFiles" doit être défini sur "inPartition" pour que cela prenne effet.

- **GroupFiles** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le groupement de fichiers est activé par défaut lorsque l'entrée contient plus de 50 000 fichiers. Pour activer le groupement lorsqu'il y a moins de 50 000 fichiers, définissez ce paramètre sur « inPartition ». Pour désactiver le groupement lorsqu'il y a plus de 50 000 fichiers, définissez ce paramètre sur "none".

- **Recurse** – Booléen.

Si ce paramètre est défini sur « VRAI », les fichiers sont lus de manière récursive dans tous les sous-répertoires des chemins spécifiés.

- **MaxBand** – Nombre (entier), pas plus qu'Aucun.

Cette option permet de contrôler la durée, en millisecondes, au delà de laquelle la liste S3 est susceptible d'être cohérente. Les fichiers dont l'horodatage des modifications se situe dans les dernières millisecondes de MaxBand sont suivis, en particulier lors de leur utilisation, afin de tenir compte de la cohérence éventuelle JobBookmarks d'Amazon S3. La plupart des utilisateurs n'ont pas besoin de définir cette option. La valeur par défaut est 900 000 millisecondes, soit 15 minutes.

- **MaxFilesInBand** – Nombre (entier), pas plus qu'Aucun.

Cette option Indique le nombre maximal de fichiers à enregistrer à partir des dernières secondes maxBand. Si ce nombre est dépassé, les fichiers supplémentaires sont ignorés et traités dans l'exécution de tâche suivante.

- **AdditionalOptions** – Un objet [S3 DirectSourceAdditionalOptions](#).

Indique des options de connexion supplémentaires.

- `OutputSchemas` – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la source S3 Parquet.

DeltaSource Structure S3

Spécifie une source de données Delta Lake stockée dans Amazon S3.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la source de Delta Lake.

- `Paths` – Obligatoire : Tableau de chaînes UTF-8.

Une liste de chemins Amazon S3 à lire.

- `AdditionalDeltaOptions` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique des options de connexion supplémentaires.

- `AdditionalOptions` – Un objet [S3 DirectSourceAdditionalOptions](#).

Indique les options supplémentaires du connecteur.

- `OutputSchemas` – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la source Delta Lake.

CatalogDeltaSource Structure S3

Spécifie une source de données Delta Lake enregistrée dans le catalogue de AWS Glue données. La source de données doit être stockée dans Amazon S3.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la source de données Delta Lake.

- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données à partir de laquelle lire les données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la base de données à partir de laquelle lire les données.

- **AdditionalDeltaOptions** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique des options de connexion supplémentaires.

- **OutputSchemas** – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la source Delta Lake.

CatalogDeltaSource structure

Spécifie une source de données Delta Lake enregistrée dans le catalogue de AWS Glue données.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la source de données Delta Lake.

- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données à partir de laquelle lire les données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la base de données à partir de laquelle lire les données.

- **AdditionalDeltaOptions** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique des options de connexion supplémentaires.

- **OutputSchemas** – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la source Delta Lake.

HudiSource Structure S3

Spécifie une source de données Hudi stockée dans Amazon S3

Champs

- Name – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source Hudi.

- Paths – Obligatoire : Tableau de chaînes UTF-8.

Une liste de chemins Amazon S3 à lire.

- AdditionalHudiOptions – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique des options de connexion supplémentaires.

- AdditionalOptions – Un objet [S3 DirectSourceAdditionalOptions](#).

Indique les options supplémentaires du connecteur.

- OutputSchemas – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la source Hudi.

CatalogHudiSource Structure S3

Spécifie une source de données Hudi enregistrée dans le catalogue de AWS Glue données. La source de données Hudi doit être stockée dans Amazon S3.

Champs

- Name – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source de données Hudi.

- Database – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données à partir de laquelle lire les données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la base de données à partir de laquelle lire les données.

- **AdditionalHudiOptions** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique des options de connexion supplémentaires.

- **OutputSchemas** – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la source Hudi.

ExcelSource Structure S3

Spécifie une source de données S3 Excel.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source de données S3 Excel.

- **Paths** – Obligatoire : Tableau de chaînes UTF-8.

Les chemins S3 où se trouvent les fichiers Excel.

- **CompressionType** – Chaîne UTF-8 (valeurs valides: snappy="SNAPPY" | lzo="LZO" | gzip="GZIP" | brotli="BROTLI" | lz4="LZ4" | uncompressed="UNCOMPRESSED" | none="NONE").

Format de compression utilisé pour les fichiers Excel.

- **Exclusions** – Tableau de chaînes UTF-8.

Modèles permettant d'exclure des fichiers ou des chemins spécifiques du traitement.

- **GroupSize** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Définit la taille des groupes de fichiers pour le traitement par lots.

- `GroupFiles` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Spécifie la manière dont les fichiers doivent être regroupés pour être traités.

- `Recurse` – Booléen.

Indique s'il faut traiter les sous-répertoires de manière récursive.

- `MaxBand` – Nombre (entier), pas plus qu'Aucun.

Le nombre maximal de bandes de traitement à utiliser.

- `MaxFilesInBand` – Nombre (entier), pas plus qu'Aucun.

Le nombre maximum de fichiers à traiter dans chaque bande.

- `AdditionalOptions` – Un objet [S3 DirectSourceAdditionalOptions](#).

Options de configuration supplémentaires pour le traitement direct des sources dans S3.

- `NumberRows` – Nombre (long).

Le nombre de lignes à traiter à partir de chaque fichier Excel.

- `SkipFooter` – Nombre (entier), pas plus qu'Aucun.

Nombre de lignes à ignorer à la fin de chaque fichier Excel.

- `OutputSchemas` – Un tableau d'objets [GlueSchema](#).

Les AWS Glue schémas à appliquer aux données traitées.

CatalogHudiSource structure

Spécifie une source de données Hudi enregistrée dans le catalogue de AWS Glue données.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source de données Hudi.

- `Database` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données à partir de laquelle lire les données.

- `Table` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la base de données à partir de laquelle lire les données.

- `AdditionalHudiOptions` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique des options de connexion supplémentaires.

- `OutputSchemas` – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la source Hudi.

Structure de Dynamo DBCatalog Source

Spécifie une source de données DynamoDB dans AWS Glue le catalogue de données.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source de données.

- `Database` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données à partir de laquelle lire les données.

- `Table` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la base de données à partir de laquelle lire les données.

RelationalCatalogSource structure

Indique une source de données de base de données relationnelle dans le catalogue de données AWS Glue .

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de la source de données.

- `Database` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données à partir de laquelle lire les données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la base de données à partir de laquelle lire les données.

JDBCConnectorStructure de la cible

Indique une cible de données qui écrit sur Amazon S3 dans un stockage en colonnes Apache Parquet.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- **ConnectionName** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la connexion associée au connecteur.

- **ConnectionTable** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table dans la cible de données.

- **ConnectorName** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom d'un connecteur qui sera utilisé.

- **ConnectionType** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Type de connexion, tel que marketplace.jdbc ou custom.jdbc, désignant une connexion à une cible de données JDBC.

- **AdditionalOptions** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Options de connexion supplémentaires pour le connecteur.

- `OutputSchemas` – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la cible JDBC.

SparkConnectorTarget structure

Indique une cible qui utilise un connecteur Apache Spark.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- `Inputs` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- `ConnectionName` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom d'une connexion pour un connecteur Apache Spark.

- `ConnectorName` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom d'un connecteur Apache Spark.

- `ConnectionType` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Type de connexion, tel que `marketplace.spark` ou `custom.spark`, désignant une connexion à un stocker de données Apache Spark.

- `AdditionalOptions` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Options de connexion supplémentaires pour le connecteur.

- `OutputSchemas` – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la cible Spark personnalisée.

BasicCatalogTarget structure

Spécifie une cible qui utilise une table AWS Glue de catalogue de données.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de votre cible de données.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- **PartitionKeys** – Tableau de chaînes UTF-8.

Les clés de partition utilisées pour distribuer les données sur plusieurs partitions ou partitions en fonction d'une clé ou d'un ensemble de clés spécifique.

- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

La base de données où se trouve la table que vous souhaitez utiliser comme cible. Cette base de données doit déjà exister dans le catalogue de données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

La table qui définit le schéma de vos données de sortie. Cette table doit déjà exister dans le catalogue de données..

Structure de My SQLCatalog Target

Indique une cible qui utilise MySQL.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données dans laquelle écrire les données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table de la base de données dans laquelle écrire les données.

Structure de SQLCatalog PostgreTarget

Indique une cible qui utilise Postgre SQL.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données dans laquelle écrire les données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table de la base de données dans laquelle écrire les données.

Structure d'Oracle SQLCatalog Target

Indique une cible qui utilise Oracle SQL.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données dans laquelle écrire les données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table de la base de données dans laquelle écrire les données.

SQLServerCatalogTarget Structure de Microsoft

Indique une cible qui utilise Microsoft SQL.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données dans laquelle écrire les données.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table de la base de données dans laquelle écrire les données.

RedshiftTarget structure

Indique une cible qui utilise Amazon Redshift.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- **Database** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données dans laquelle écrire les données.

- `Table` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table de la base de données dans laquelle écrire les données.

- `RedshiftTmpDir` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chemin Amazon S3 où les données temporaires peuvent être stockées lors de la copie à partir de la base de données.

- `TmpDirIAMRole` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le rôle IAM avec les autorisations.

- `UpsertRedshiftOptions` – Un objet [UpsertRedshiftTargetOptions](#).

Jeu d'options permettant de configurer une opération de mise à jour/insertion lors de l'écriture vers une cible Redshift.

AmazonRedshiftTarget structure

Indique une cible Amazon Redshift.

Champs

- `Name` – Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible Amazon Redshift.

- `Data` – Un objet [AmazonRedshiftNodeData](#).

Indique les données du nœud cible Amazon Redshift.

- `Inputs` : tableau de chaînes UTF-8, avec une chaîne minimum et une chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

UpsertRedshiftTargetOptions structure

Options permettant de configurer une opération de mise à jour/insertion lors de l'écriture vers une cible Redshift.

Champs

- `TableLocation` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Emplacement physique de la table Redshift.

- `ConnectionName` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Nom de la connexion à utiliser pour écrire dans Redshift.

- `UpsertKeys` – Tableau de chaînes UTF-8.

Clés utilisées pour déterminer si une opération de mise à jour ou d'insertion est nécessaire.

CatalogTarget Structure S3

Spécifie une cible de données qui écrit sur Amazon S3 à l'aide du catalogue de AWS Glue données.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- `Inputs` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- `PartitionKeys` – Tableau de chaînes UTF-8.

Indique le partitionnement natif à l'aide d'une séquence de clés.

- `Table` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table de la base de données dans laquelle écrire les données.

- `Database` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données dans laquelle écrire les données.

- `SchemaChangePolicy` – Un objet [CatalogSchemaChangePolicy](#).

Une politique qui indique les évolutions de mise à jour pour le crawler.

GlueParquetTarget Structure S3

Indique une cible de données qui écrit sur Amazon S3 dans un stockage en colonnes Apache Parquet.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- **PartitionKeys** – Tableau de chaînes UTF-8.

Indique le partitionnement natif à l'aide d'une séquence de clés.

- **Path** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Un seul chemin Amazon S3 sur lequel écrire.

- **Compression** – Chaîne UTF-8 (valeurs valides: `snappy="SNAPPY" | lzo="LZO" | gzip="GZIP" | brotli="BROTLI" | lz4="LZ4" | uncompressed="UNCOMPRESSED" | none="NONE"`).

Indique la manière dont les données sont comprimées. Ce n'est généralement pas nécessaire si le fichier de données a une extension standard. Les valeurs possibles sont "gzip" et "bzip").

- **NumberTargetPartitions** – Chaîne UTF-8.

Spécifie le nombre de partitions cibles pour les fichiers Parquet lorsque vous écrivez sur Amazon S3 à l'aide de AWS Glue.

- **SchemaChangePolicy** – Un objet [DirectSchemaChangePolicy](#).

Une politique qui indique les évolutions de mise à jour pour le crawler.

CatalogSchemaChangePolicy structure

Une politique qui indique des comportements de mise à jour pour l'crawler.

Champs

- `EnableUpdateCatalog` – Booléen.

S'il faut utiliser ou non le comportement de mise à jour spécifié lorsque l'crawler détecte un schéma modifié.

- `UpdateBehavior` – Chaîne UTF-8 (valeurs valides : `UPDATE_IN_DATABASE` | `LOG`).

Comportement de mise à jour lorsque le crawler détecte un schéma modifié.

DirectTarget Structure S3

Indique une cible de données qui écrit dans Amazon S3.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- `Inputs` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- `PartitionKeys` – Tableau de chaînes UTF-8.

Indique le partitionnement natif à l'aide d'une séquence de clés.

- `Path` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Un seul chemin Amazon S3 sur lequel écrire.

- `Compression` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique la manière dont les données sont comprimées. Ce n'est généralement pas nécessaire si le fichier de données a une extension standard. Les valeurs possibles sont "gzip" et "bzip").

- `NumberTargetPartitions` – Chaîne UTF-8.

Spécifie le nombre de partitions cibles lors de l'écriture de données directement sur Amazon S3.

- `Format`— Obligatoire : chaîne UTF-8 (valeurs valides : `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

Définit le format de sortie des données pour la cible.

- `SchemaChangePolicy` – Un objet [DirectSchemaChangePolicy](#).

Une politique qui indique les évolutions de mise à jour pour le crawler.

HudiCatalogTarget Structure S3

Spécifie une cible qui écrit dans une source de données Hudi du catalogue de AWS Glue données.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- `Inputs` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- `PartitionKeys` – Tableau de chaînes UTF-8.

Indique le partitionnement natif à l'aide d'une séquence de clés.

- `Table` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table de la base de données dans laquelle écrire les données.

- `Database` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données dans laquelle écrire les données.

- `AdditionalOptions` – obligatoire : tableau de mappage de paires clé-valeur.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique des options de connexion supplémentaires pour le connecteur.

- `SchemaChangePolicy` – Un objet [CatalogSchemaChangePolicy](#).

Une politique qui indique les évolutions de mise à jour pour le crawler.

HudiDirectTarget Structure S3

Spécifie une cible qui écrit dans une source de données Hudi en Amazon S3.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- **Path** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le chemin d'accès Amazon S3 de votre source de données Hudi sur laquelle écrire.

- **Compression** – Obligatoire : Chaîne UTF-8 (valeurs valides : `gzip="GZIP" | lzo="LZO" | uncompressed="UNCOMPRESSED" | snappy="SNAPPY"`).

Indique la manière dont les données sont comprimées. Ce n'est généralement pas nécessaire si le fichier de données a une extension standard. Les valeurs possibles sont "gzip" et "bzip").

- **NumberTargetPartitions** – Chaîne UTF-8.

Spécifie le nombre de partitions cibles pour distribuer les fichiers de jeux de données Hudi sur Amazon S3.

- **PartitionKeys** – Tableau de chaînes UTF-8.

Indique le partitionnement natif à l'aide d'une séquence de clés.

- **Format**— Obligatoire : chaîne UTF-8 (valeurs valides : `json="JSON" | csv="CSV" | avro="AVRO" | orc="ORC" | parquet="PARQUET" | hudi="HUDI" | delta="DELTA" | iceberg="ICEBERG" | hyper="HYPER" | xml="XML"`).

Définit le format de sortie des données pour la cible.

- **AdditionalOptions** – obligatoire : tableau de mappage de paires clé-valeur.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique des options de connexion supplémentaires pour le connecteur.

- SchemaChangePolicy – Un objet [DirectSchemaChangePolicy](#).

Une politique qui indique les évolutions de mise à jour pour le crawler.

DeltaCatalogTarget Structure S3

Spécifie une cible qui écrit dans une source de données Delta Lake dans le catalogue de AWS Glue données.

Champs

- Name – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- Inputs – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- PartitionKeys – Tableau de chaînes UTF-8.

Indique le partitionnement natif à l'aide d'une séquence de clés.

- Table – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table de la base de données dans laquelle écrire les données.

- Database – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données dans laquelle écrire les données.

- AdditionalOptions – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique des options de connexion supplémentaires pour le connecteur.

- SchemaChangePolicy – Un objet [CatalogSchemaChangePolicy](#).

Une politique qui indique les évolutions de mise à jour pour le crawler.

DeltaDirectTarget Structure S3

Spécifie une cible qui écrit dans une source de données de Delta Lake en Amazon S3.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- **PartitionKeys** – Tableau de chaînes UTF-8.

Indique le partitionnement natif à l'aide d'une séquence de clés.

- **Path** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le chemin d'accès Amazon S3 de votre source de données Delta Lake sur laquelle écrire.

- **Compression** – Obligatoire : Chaîne UTF-8 (valeurs valides : `uncompressed="UNCOMPRESSED"` | `snappy="SNAPPY"`).

Indique la manière dont les données sont comprimées. Ce n'est généralement pas nécessaire si le fichier de données a une extension standard. Les valeurs possibles sont `"gzip"` et `"bzip"`.

- **NumberTargetPartitions** – Chaîne UTF-8.

Spécifie le nombre de partitions cibles pour la distribution des fichiers de données Delta Lake sur Amazon S3.

- **Format**— Obligatoire : chaîne UTF-8 (valeurs valides : `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

Définit le format de sortie des données pour la cible.

- **AdditionalOptions** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique des options de connexion supplémentaires pour le connecteur.

- SchemaChangePolicy – Un objet [DirectSchemaChangePolicy](#).

Une politique qui indique les évolutions de mise à jour pour le crawler.

HyperDirectTarget Structure S3

Spécifie une cible de HyperDirect données qui écrit sur Amazon S3.

Champs

- Name – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Identifiant unique du nœud HyperDirect cible.

- Inputs – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Spécifie la source d'entrée pour la HyperDirect cible.

- PartitionKeys – Tableau de chaînes UTF-8.

Définit la stratégie de partitionnement des données de sortie.

- Path – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Emplacement S3 où les données de sortie seront écrites.

- Compression – Chaîne UTF-8 (valeurs valides : uncompressed="UNCOMPRESSED").

Type de compression à appliquer aux données de sortie.

- SchemaChangePolicy – Un objet [DirectSchemaChangePolicy](#).

Définit la manière dont les modifications de schéma sont gérées lors des opérations d'écriture.

IcebergDirectTarget Structure S3

Spécifie une cible qui écrit dans une source de données Iceberg dans Amazon S3.

Champs

- Name – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Spécifie l'identifiant unique du nœud cible Iceberg dans votre pipeline de données.

- Inputs – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Définit la source d'entrée unique qui fournit des données à cette cible Iceberg.

- `PartitionKeys` – Tableau de chaînes UTF-8.

Spécifie les colonnes utilisées pour partitionner les données de la table Iceberg dans S3.

- `Path` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Définit l'emplacement S3 où les données de la table Iceberg seront stockées.

- `Format`— Obligatoire : chaîne UTF-8 (valeurs valides : `json="JSON" | csv="CSV" | avro="AVRO" | orc="ORC" | parquet="PARQUET" | hudi="HUDI" | delta="DELTA" | iceberg="ICEBERG" | hyper="HYPER" | xml="XML"`).

Spécifie le format de fichier utilisé pour stocker les données des tables Iceberg (par exemple, Parquet, ORC).

- `AdditionalOptions` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Fournit des options de configuration supplémentaires pour personnaliser le comportement de la table Iceberg.

- `SchemaChangePolicy` – Un objet [DirectSchemaChangePolicy](#).

Définit la manière dont les modifications de schéma sont gérées lors de l'écriture de données dans la table Iceberg.

- `Compression` – Obligatoire : Chaîne UTF-8 (valeurs valides : `gzip="GZIP" | lzo="LZO" | uncompressed="UNCOMPRESSED" | snappy="SNAPPY"`).

Spécifie le codec de compression utilisé pour les fichiers de table Iceberg dans S3.

- `NumberTargetPartitions` – Chaîne UTF-8.

Définit le nombre de partitions cibles pour la distribution des fichiers de table Iceberg dans S3.

DirectSchemaChangePolicy structure

Une politique qui indique des comportements de mise à jour pour l'crawler.

Champs

- `EnableUpdateCatalog` – Booléen.

S'il faut utiliser ou non le comportement de mise à jour spécifié lorsque l'crawler détecte un schéma modifié.

- `UpdateBehavior` – Chaîne UTF-8 (valeurs valides : `UPDATE_IN_DATABASE` | `LOG`).

Comportement de mise à jour lorsque l'crawler détecte un schéma modifié.

- `Table` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique la table de la base de données à laquelle s'applique la politique de modification du schéma.

- `Database` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique la base de données à laquelle s'applique la politique de modification du schéma.

ApplyMapping structure

Indique une transformation qui mappe les clés de propriétés de données de la source de données aux clés de propriété de données de la cible de données. Vous pouvez renommer les clés, modifier leur type de données et choisir les clés à supprimer du jeu de données.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- `Inputs` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- `Mapping` – Obligatoire : Un tableau d'objets [Mappage](#).

Indique le mappage des clés de propriétés de données de la source de données avec les clés de propriétés de données de la cible de données.

Structure de mappage

Indique le mappage des clés de propriété de données.

Champs

- ToKey – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Après le mappage d'application, quel nom donner à la colonne. Peut être similaire à FromPath.

- FromPath – Tableau de chaînes UTF-8.

La table ou la colonne à modifier.

- FromType – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le type des données à modifier.

- ToType – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le type de données sous lequel les données doivent être modifiées.

- Dropped – Booléen.

Si ce paramètre est défini sur « VRAI », la colonne est supprimée.

- Children – Un tableau d'objets [Mappage](#).

S'applique uniquement aux structures de données imbriquées. Si vous souhaitez modifier la structure parente, mais également l'un de ses enfants, vous pouvez remplir cette structure de données. C'est aussi Mapping, mais son FromPath sera le FromPath du parent plus le FromPath provenant de cette structure.

Pour la partie enfants, supposons que vous ayez la structure suivante :

```
{ "FromPath": "OuterStructure", "ToKey": "OuterStructure", "ToType":  
"Struct", "Dropped": false, "Children": [{ "FromPath": "inner", "ToKey":  
"inner", "ToType": "Double", "Dropped": false, }] }
```

Vous pouvez Indiquer un Mapping qui se présente sous la forme suivante :

```
{ "FromPath": "OuterStructure", "ToKey": "OuterStructure", "ToType":  
"Struct", "Dropped": false, "Children": [{ "FromPath": "inner", "ToKey":  
"inner", "ToType": "Double", "Dropped": false, }] }
```

SelectFields structure

Indique une transformation qui choisit les clés de propriété de données que vous souhaitez conserver.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- **Paths** – Obligatoire : Tableau de chaînes UTF-8.

Un chemin JSON vers une variable de la structure de données.

DropFields structure

Indique une transformation qui choisit les clés de propriété de données que vous souhaitez supprimer.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- **Paths** – Obligatoire : Tableau de chaînes UTF-8.

Un chemin JSON vers une variable de la structure de données.

RenameField structure

Indique une transformation qui renomme une clé de propriété de données unique.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- **SourcePath** – Obligatoire : Tableau de chaînes UTF-8.

Un chemin JSON vers une variable de la structure de données pour les données source.

- **TargetPath** – Obligatoire : Tableau de chaînes UTF-8.

Un chemin JSON vers une variable de la structure de données pour les données cibles.

Structure Spigot

Indique une transformation qui écrit des échantillons de données dans un compartiment Amazon S3.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- **Path** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Un chemin dans Amazon S3 où la transformation écrira un sous-ensemble de registres à partir du jeu de données dans un fichier JSON situé dans un compartiment Amazon S3.

- **Topk** – Nombre (entier), 100 au maximum.

Indique un certain nombre de registres à écrire à partir du début du jeu de données.

- **Prob** – Nombre (double), 1 au maximum.

La probabilité (valeur décimale ayant une valeur maximale de 1) de prélèvement d'un registre donné. La valeur 1 indique que chaque ligne lue à partir du jeu de données doit être incluse dans l'exemple de sortie.

Structure Join

Indique une transformation qui joint deux jeux de données en un jeu de données à l'aide d'une phrase de comparaison sur les clés de propriété de données spécifiées. Vous pouvez utiliser des jointures internes (ou intérieures), externes (ou extérieures), gauche, droite, semi gauche et anti gauche.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 2 chaînes minimum et 2 chaînes maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- **JoinType** – Obligatoire : Chaîne UTF-8 (valeurs valides : `equi join="EQUIJOIN"` | `left="LEFT"` | `right="RIGHT"` | `outer="OUTER"` | `leftsemi="LEFT_SEMI"` | `leftanti="LEFT_ANTI"`).

Indique le type de jointure à effectuer sur les jeux de données.

- **Columns** – Obligatoire : Tableau d'objets [JoinColumn](#), 2 structures minimum et 2 structures maximum.

Liste des deux colonnes à joindre.

JoinColumn structure

Indique une colonne à joindre.

Champs

- **From** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

La colonne à joindre.

- **Keys** – Obligatoire : Tableau de chaînes UTF-8.

La clé de la colonne à joindre.

SplitFields structure

Indique une transformation qui divise les clés de propriété de données en deux `DynamicFrames`. Le résultat est une collection de `DynamicFrames` : une avec les clés de propriété de données sélectionnées, et une autre avec les clés de propriété de données restantes.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- **Paths** – Obligatoire : Tableau de chaînes UTF-8.

Un chemin JSON vers une variable de la structure de données.

SelectFromCollection structure

Indique une transformation qui en choisit une `DynamicFrame` provenant d'une collection de `DynamicFrames`. Le résultat est le `DynamicFrame` sélectionné

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- **Index** – Obligatoire : Nombre (entier), pas plus qu'Aucun.

L'index du `DynamicFrame` à sélectionner.

FillMissingValues structure

Précise une transformation qui localise les registres dans le jeu de données dont les valeurs sont manquantes et ajoute un nouveau champ avec une valeur déterminée par imputation. Le jeu de

données source est utilisé pour entraîner le modèle de machine learning (ML) qui détermine la valeur manquante.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- **ImputedPath** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Un chemin JSON vers une variable de la structure de données pour le jeu de données attribué.

- **FilledPath** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Un chemin JSON vers une variable de la structure de données pour le jeu de données rempli.

Structure Filtre

Indique une transformation qui divise un jeu de données en deux, en fonction d'une condition de filtre.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- **LogicalOperator** – Obligatoire : Chaîne UTF-8 (valeurs valides : AND | OR).

L'opérateur utilisé pour filtrer les lignes en comparant la valeur clé à une valeur spécifiée.

- **Filters** – Obligatoire : Un tableau d'objets [FilterExpression](#).

Indique une expression de filtre.

FilterExpression structure

Indique une expression de filtre.

Champs

- **Operation** – Obligatoire : Chaîne UTF-8 (valeurs valides : EQ | LT | GT | LTE | GTE | REGEX | ISNULL).

Le type d'opération à effectuer dans l'expression.

- **Negated** – Booléen.

Indique si l'expression doit être annulée.

- **Values** – Obligatoire : Un tableau d'objets [FilterValue](#).

Une liste de valeurs de filtre.

FilterValue structure

Représente une entrée unique dans la liste de valeurs de `FilterExpression`.

Champs

- **Type** – Obligatoire : Chaîne UTF-8 (valeurs valides : COLUMNEXTRACTED | CONSTANT).

Le type de valeur de filtre.

- **Value** – Obligatoire : Tableau de chaînes UTF-8.

La valeur à associer.

CustomCode structure

Indique une transformation qui utilise le code personnalisé que vous fournissez pour effectuer la transformation des données. La sortie est une collection de `DynamicFrames`.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, au moins 1 chaîne.

Les entrées de données identifiées par leurs noms de nœuds.

- **Code** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #52](#).

Le code personnalisé utilisé pour effectuer la transformation des données.

- **ClassName** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom défini pour la classe de nœuds de code personnalisée.

- **OutputSchemas** – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la transformation du code personnalisé.

Structure SparkSQL

Indique une transformation dans laquelle vous saisissez une requête SQL à l'aide de la syntaxe Spark SQL pour transformer les données. Le résultat est un `DynamicFrame` unique.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, au moins 1 chaîne.

Les entrées de données identifiées par leurs noms de nœuds. Vous pouvez associer un nom de table à chaque nœud d'entrée à utiliser dans la requête SQL. Le nom que vous choisissez doit respecter les restrictions de dénomination Spark SQL.

- **SqlQuery** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #60](#).

Une requête SQL qui doit utiliser la syntaxe Spark SQL et renvoyer un jeu de données unique.

- **SqlAliases** – Obligatoire : Un tableau d'objets [SqlAlias](#).

Liste d'alias Un alias vous autorise de spécifier le nom à utiliser dans SQL pour une entrée donnée. Par exemple, vous avez une source de données nommée « MyDataSource ». Si vous spécifiez `From as MyDataSource` et `Alias as SqlName`, alors dans votre code SQL, vous pouvez faire :

```
select * from SqlName
```

et qui obtient des données de MyDataSource.

- `OutputSchemas` – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la transformation SparkSQL.

SqlAlias structure

Représente une entrée unique dans la liste de valeurs de `SqlAliases`.

Champs

- `From` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Une table ou une colonne d'une table.

- `Alias` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Un nom temporaire donné à une table ou à une colonne d'une table.

DropNullFields structure

Indique une transformation qui supprime les colonnes du jeu de données si toutes les valeurs de la colonne sont « nulles ». Par défaut, AWS Glue Studio reconnaît les objets nuls, mais certaines valeurs telles que les chaînes vides, les chaînes « nulles », les entiers -1 ou d'autres espaces réservés tels que les zéros ne sont pas automatiquement reconnues comme nulles.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- `Inputs` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- `NullCheckBoxList` – Un objet [NullCheckBoxList](#).

Une structure qui indique si certaines valeurs sont reconnues comme des valeurs null en vue de la suppression.

- `NullTextList` – Un tableau d'objets [NullValueField](#), 50 structures maximum.

Structure qui spécifie une liste de `NullValueField` structures représentant une valeur nulle personnalisée telle que zéro ou une autre valeur utilisée comme espace réservé nul propre à l'ensemble de données.

La transformation `DropNullFields` supprime les valeurs nulles personnalisées uniquement, si la valeur de l'espace réservé nul et du type de données correspondent aux données.

NullCheckBoxList structure

Indique si certaines valeurs sont reconnues comme des valeurs null en vue de la suppression.

Champs

- `IsEmpty` – Booléen.

Indique qu'une chaîne vide est considérée comme une valeur null.

- `IsNullString` – Booléen.

Indique qu'une valeur révélant le mot « null » est considérée comme une valeur null.

- `IsNegOne` – Booléen.

Indique qu'une valeur entière de -1 est considérée comme une valeur null.

NullValueField structure

Représente une valeur null personnalisée telle qu'un zéro ou une autre valeur utilisée comme espace réservé nul unique pour le jeu de données.

Champs

- `Value` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

La valeur de l'espace réservé nul.

- `Datatype` – Obligatoire : un objet [Datatype](#).

Le type de données de la valeur.

Structure Datatype

Une structure représentant le type de données de la valeur.

Champs

- **Id** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Le type de données de la valeur.

- **Label** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Une étiquette affectée au type de données.

Structure Fusion

Indique une transformation qui fusionne une `DynamicFrame` avec une `DynamicFrame` intermédiaire basée sur les clés primaires spécifiées pour identifier les registres. Les registres en double (registres avec les mêmes clés primaires) ne sont pas dédupliqués.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 2 chaînes minimum et 2 chaînes maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- **Source** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

La source `DynamicFrame` qui sera fusionnée avec une `DynamicFrame` intermédiaire.

- **PrimaryKeys** – Obligatoire : Tableau de chaînes UTF-8.

La liste des champs de clé primaire permettant de faire correspondre les registres des trames dynamiques source et intermédiaire.

Structure Union

Indique une transformation qui combine les lignes de deux jeux de données ou plus en un seul résultat.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 2 chaîne minimum et 2 chaîne maximum.

Les entrées de l'ID du nœud dans la transformation.

- **UnionType** – Obligatoire : Chaîne UTF-8 (valeurs valides : ALL | DISTINCT).

Indique le type de transformation Union.

Spécifiez ALL de joindre toutes les lignes des sources de données au résultat DynamicFrame. L'union qui en résulte ne supprime pas les lignes en double.

Spécifiez DISTINCT de supprimer les lignes dupliquées dans le résultat DynamicFrame.

PIIDetection structure

Indique une transformation qui identifie, supprime ou masque les données d'informations personnelles identifiables (PII).

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les entrées de l'ID du nœud dans la transformation.

- **PiiType** – Obligatoire : Chaîne UTF-8 (valeurs valides : RowAudit | RowMasking | ColumnAudit | ColumnMasking).

Indique le type de PIIDetection transformation.

- **EntityTypesToDetect** – Obligatoire : Tableau de chaînes UTF-8.

Indique les types d'entités que la PII Detection transformation identifiera en tant que données PII.

Les entités de type PII comprennent : PERSON_NAME, DATE, USA_SNN, EMAIL, USA_ITIN, USA_PASSPORT_NUMBER, PHONE_NUMBER, BANK_ACCOUNT, IP_ADDRESS, MAC_ADDRESS, USA_CPT_CODE, USA_HCPCS_CODE, USA_NATIONAL_DRUG_CODE, USA_MEDICARE_BENEFICIARY_IDENTIFIER, USA_HEALTH_INSURANCE_CLAIM_NUMBER, CREDIT_CARD, USA_NATIONAL_PROVIDER_IDENTIFIER, USA_DEA_NUMBER, USA_DRIVING_LICENSE

- **OutputColumnName** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique le nom de la colonne de sortie qui contiendra tout type d'entité détecté dans cette ligne.

- **SampleFraction** – Nombre (double), 1 au maximum.

Indique la fraction des données à échantillonner lors de la recherche d'entités PII.

- **ThresholdFraction** – Nombre (double), 1 au maximum.

Indique la fraction des données qui doit être satisfaite pour qu'une colonne soit identifiée comme données PII.

- **MaskValue** – chaîne UTF-8, d'une longueur ne dépassant pas 256 octets, correspondant au [Custom string pattern #56](#).

Indique la valeur qui remplacera l'entité détectée.

Structure Aggregate

Indique une transformation qui regroupe les lignes par champs choisis et calcule la valeur agrégée par fonction spécifiée.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Indique les champs et les lignes à utiliser comme entrées pour la transformation agrégée.

- **Groups** – Obligatoire : Tableau de chaînes UTF-8.

Indique les champs à regrouper.

- **Aggs** – Obligatoire : tableau d'objets [AggregateOperation](#), 1 structure minimum et 30 structures maximum.

Indique les fonctions d'agrégation à exécuter sur des champs spécifiés.

DropDuplicates structure

Indique une transformation qui supprime des lignes de données répétitives d'un jeu de données.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud de transformation.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les entrées de données identifiées par leurs noms de nœuds.

- **Columns** – Tableau de chaînes UTF-8.

Nom des colonnes à fusionner ou à supprimer en cas de répétition.

GovernedCatalogTarget structure

Spécifie une cible de données qui écrit sur Amazon S3 à l'aide du catalogue de AWS Glue données.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible de données.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

- **PartitionKeys** – Tableau de chaînes UTF-8.

Indique le partitionnement natif à l'aide d'une séquence de clés.

- **Table** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la table de la base de données dans laquelle écrire les données.

- Database – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Le nom de la base de données dans laquelle écrire les données.

- SchemaChangePolicy – Un objet [CatalogSchemaChangePolicy](#).

Politique qui indique des comportements de mise à jour pour le catalogue gouverné.

GovernedCatalogSource structure

Spécifie le magasin de données dans le catalogue de AWS Glue données régi.

Champs

- Name – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du stocker de données.

- Database – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

La base de données à partir de laquelle lire les données.

- Table – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Table de base de données à lire.

- PartitionPredicate – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Les partitions satisfaisant à ce prédicat sont supprimées. Les fichiers qui se situent dans la période de conservation pour ces partitions ne sont pas supprimés. Valeur définie sur "" – vide par défaut.

- AdditionalOptions – Un objet [S3 SourceAdditionalOptions](#).

Indique des options de connexion supplémentaires.

AggregateOperation structure

Indique l'ensemble de paramètres permettant d'effectuer l'agrégation de la transformation agrégée.

Champs

- Column – Obligatoire : Tableau de chaînes UTF-8.

Indique la colonne du jeu de données sur lequel la fonction d'agrégation sera appliquée.

- AggFunc – Obligatoire : chaîne UTF-8 (valeurs valides : avg | countDistinct | count | first | last | kurtosis | max | min | skewness | stddev_samp | stddev_pop | sum | sumDistinct | var_samp | var_pop).

Indique la fonction d'agrégation à appliquer.

Les fonctions d'agrégation possibles incluent : avg countDistinct, count, first, last, kurtosis, max, min, skewness, stddev_samp, stddev_pop, sum, sumDistinct, var_samp, var_pop

GlueSchema structure

Indique un schéma défini par l'utilisateur lorsqu'un schéma ne peut pas être déterminé par AWS Glue.

Champs

- Columns – Un tableau d'objets [GlueStudioSchemaColumn](#).

Spécifie les définitions de colonnes qui constituent un AWS Glue schéma.

GlueStudioSchemaColumn structure

Spécifie une seule colonne dans une définition de AWS Glue schéma.

Champs

- Name : Requis : chaîne UTF-8, d'une longueur maximale de 1 024 octets, correspondant au [Single-line string pattern](#).

Nom de la colonne dans le schéma AWS Glue Studio.

- Type – Chaîne UTF-8, d'une longueur maximale de 131 072 octets, correspondant au [Single-line string pattern](#).

Type de ruche pour cette colonne dans le schéma AWS Glue Studio.

GlueStudioColumn structure

Spécifie une seule colonne dans AWS Glue Studio.

Champs

- **Key** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

La clé de la colonne dans AWS Glue Studio.

- **FullPath** – Obligatoire : Tableau de chaînes UTF-8.

TTThe URL complète de la colonne dans AWS Glue Studio.

- **Type** : requis : chaîne UTF-8 (valeurs valides : `array="ARRAY" | bigint="BIGINT" | bigint array="BIGINT_ARRAY" | binary="BINARY" | binary array="BINARY_ARRAY" | boolean="BOOLEAN" | boolean array="BOOLEAN_ARRAY" | byte="BYTE" | byte array="BYTE_ARRAY" | char="CHAR" | char array="CHAR_ARRAY" | choice="CHOICE" | choice array="CHOICE_ARRAY" | date="DATE" | date array="DATE_ARRAY" | decimal="DECIMAL" | decimal array="DECIMAL_ARRAY" | double="DOUBLE" | double array="DOUBLE_ARRAY" | enum="ENUM" | enum array="ENUM_ARRAY" | float="FLOAT" | float array="FLOAT_ARRAY" | int="INT" | int array="INT_ARRAY" | interval="INTERVAL" | interval array="INTERVAL_ARRAY" | long="LONG" | long array="LONG_ARRAY" | object="OBJECT" | short="SHORT" | short array="SHORT_ARRAY" | smallint="SMALLINT" | smallint array="SMALLINT_ARRAY" | string="STRING" | string array="STRING_ARRAY" | timestamp="TIMESTAMP" | timestamp array="TIMESTAMP_ARRAY" | tinyint="TINYINT" | tinyint array="TINYINT_ARRAY" | varchar="VARCHAR" | varchar array="VARCHAR_ARRAY" | null="NULL" | unknown="UNKNOWN" | unknown array="UNKNOWN_ARRAY"`).

TTThe type de colonne dans AWS Glue Studio.

- **Children** : tableau d'une structure.

TTThe enfants de la colonne parent dans AWS Glue Studio.

DynamicTransform structure

Spécifie l'ensemble de paramètres permettant d'effectuer la transformation dynamique.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Spécifie le nom de la transformation dynamique.

- **TransformName** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Spécifie le nom de la transformation dynamique tel qu'il apparaît dans l'éditeur visuel de AWS Glue Studio.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Spécifie les entrées requises pour la transformation dynamique.

- **Parameters** – Un tableau d'objets [TransformConfigParameter](#).

Spécifie les paramètres de la transformation dynamique.

- **FunctionName** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Spécifie le nom de la fonction de la transformation dynamique.

- **Path** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Spécifie le chemin de la source de transformation dynamique et des fichiers de configuration.

- **Version** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Ce champ n'est pas utilisé et sera obsolète dans une version ultérieure.

- **OutputSchemas** – Un tableau d'objets [GlueSchema](#).

Indique le schéma de données de la transformation dynamique.

TransformConfigParameter structure

Spécifie les paramètres du fichier de configuration de la transformation dynamique.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Spécifie le nom du paramètre dans le fichier de configuration de la transformation dynamique.

- **Type** – Obligatoire : Chaîne UTF-8 (valeurs valides : `str="STR"` | `int="INT"` | `float="FLOAT"` | `complex="COMPLEX"` | `bool="BOOL"` | `list="LIST"` | `null="NULL"`).

Spécifie le type de paramètre dans le fichier de configuration de la transformation dynamique.

- `ValidationRule` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Spécifie la règle de validation dans le fichier de configuration de la transformation dynamique.

- `ValidationMessage` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Spécifie le message de validation dans le fichier de configuration de la transformation dynamique.

- `Value` – Tableau de chaînes UTF-8.

Spécifie la valeur du paramètre dans le fichier de configuration de la transformation dynamique.

- `ListType` – Chaîne UTF-8 (valeurs valides: `str="STR" | int="INT" | float="FLOAT" | complex="COMPLEX" | bool="BOOL" | list="LIST" | null="NULL"`).

Spécifie le type de liste du paramètre dans le fichier de configuration de la transformation dynamique.

- `IsOptional` – Booléen.

Spécifie si le paramètre est facultatif ou non dans le fichier de configuration de la transformation dynamique.

EvaluateDataQuality structure

Spécifie vos critères d'évaluation de la qualité des données.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de l'évaluation de la qualité des données.

- `Inputs` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Entrées de votre évaluation de la qualité des données.

- `Ruleset` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 65536 octets, correspondant au [Custom string pattern #57](#).

Ensemble de règles pour l'évaluation de la qualité de vos données.

- `Output` – Chaîne UTF-8 (valeurs valides : `PrimaryInput | EvaluationResults`).

Résultat de votre évaluation de la qualité des données.

- `PublishingOptions` – Un objet [DQResultsPublishingOptions](#).

Options permettant de configurer le mode de publication de vos résultats.

- `StopJobOnFailureOptions` – Un objet [DQStopJobOnFailureOptions](#).

Options permettant de configurer le mode d'interruption de votre tâche en cas d'échec de l'évaluation de la qualité des données.

DQResultsPublishingOptions structure

Options permettant de configurer le mode de publication des résultats de votre évaluation de la qualité des données.

Champs

- `EvaluationContext` – Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Contexte de l'évaluation.

- `ResultsS3Prefix` – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Préfixe Amazon S3 ajouté aux résultats.

- `CloudWatchMetricsEnabled` – Booléen.

Activez les métriques pour vos résultats de qualité des données.

- `ResultsPublishingEnabled` – Booléen.

Activez la publication pour vos résultats de qualité des données.

DQStopJobOnFailureOptions structure

Options permettant de configurer le mode d'interruption de votre tâche en cas d'échec de l'évaluation de la qualité des données.

Champs

- `StopJobOnFailureTiming` – Chaîne UTF-8 (valeurs valides : `Immediate` | `AfterDataLoad`).

Quand arrêter la tâche en cas d'échec de votre évaluation de la qualité des données. Les options sont immédiates ou `AfterDataLoad`.

EvaluateDataQualityMultiFrame structure

Spécifie vos critères d'évaluation de la qualité des données.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de l'évaluation de la qualité des données.

- **Inputs** – Obligatoire : Tableau de chaînes UTF-8, au moins 1 chaîne.

Entrées de votre évaluation de la qualité des données. La première entrée de cette liste est la source de données principale.

- **AdditionalDataSources** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Les alias de toutes les sources de données, à l'exception de la source principale.

- **Ruleset** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 65536 octets, correspondant au [Custom string pattern #57](#).

Ensemble de règles pour l'évaluation de la qualité de vos données.

- **PublishingOptions** – Un objet [DQResultsPublishingOptions](#).

Options permettant de configurer le mode de publication de vos résultats.

- **AdditionalOptions** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8 (valeurs valides : `performanceTuning.caching="CacheOption" | observations.scope="ObservationsOption"`).

Chaque valeur est une chaîne UTF-8.

Options permettant de configurer le comportement d'exécution de la transformation.

- `StopJobOnFailureOptions` – Un objet [DQStopJobOnFailureOptions](#).

Options permettant de configurer le mode d'interruption de votre tâche en cas d'échec de l'évaluation de la qualité des données.

Structure de la recette

Un nœud AWS Glue Studio qui utilise une AWS Glue DataBrew recette dans les AWS Glue tâches.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom du nœud AWS Glue Studio.

- `Inputs` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 1 chaîne maximum.

Les nœuds qui sont des entrées du nœud de recette, identifiés par un identifiant.

- `RecipeReference` – Un objet [RecipeReference](#).

Référence à la DataBrew recette utilisée par le nœud.

- `RecipeSteps` – Un tableau d'objets [RecipeStep](#).

Transformez les étapes utilisées dans le nœud de recette.

RecipeReference structure

Référence à une AWS Glue DataBrew recette.

Champs

- `RecipeArn` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

L'ARN de la DataBrew recette.

- `RecipeVersion` – obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 16 octets.

Celui `RecipeVersion` de la DataBrew recette.

SnowflakeNodeData structure

Spécifie la configuration des nœuds Snowflake dans Studio. AWS Glue

Champs

- **SourceType** – Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Indique la manière dont les données extraites sont spécifiées. Valeurs valides : "table", "query".

- **Connection** – Un objet [Option](#).

Spécifie une connexion au catalogue de AWS Glue données à un point de terminaison Snowflake.

- **Schema** – Chaîne UTF-8.

Indique un schéma de base de données Snowflake que votre nœud doit utiliser.

- **Table** – Chaîne UTF-8.

Indique une table Snowflake que votre nœud doit utiliser.

- **Database** – Chaîne UTF-8.

Indique une base de données Snowflake que votre nœud doit utiliser.

- **TempDir** – Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Non utilisé actuellement.

- **IamRole** – Un objet [Option](#).

Non utilisé actuellement.

- **AdditionalOptions** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Chaque valeur est une chaîne UTF-8, correspondant au [Custom string pattern #59](#).

Indique les options supplémentaires transmises au connecteur Snowflake. Si des options sont spécifiées ailleurs dans ce nœud, elles seront prioritaires.

- **SampleQuery** – Chaîne UTF-8.

Une chaîne SQL utilisée pour récupérer des données avec le type source query.

- **PreAction** – Chaîne UTF-8.

Une chaîne SQL exécutée avant que le connecteur Snowflake n'exécute ses actions standard.

- **PostAction** – Chaîne UTF-8.

Une chaîne SQL exécutée après que le connecteur Snowflake a exécuté ses actions standard.

- **Action** – Chaîne UTF-8.

Indique l'action à effectuer lors de l'écriture dans une table contenant des données préexistantes. Valeurs valides: `append`, `merge`, `truncate`, `drop`.

- **Upsert** – Booléen.

Utilisé lorsque action est `append`. Indique le comportement de résolution lorsqu'une ligne existe déjà. Si la valeur est vraie, les lignes préexistantes seront mises à jour. Si la valeur est fausse, ces lignes seront insérées.

- **MergeAction** – Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Indique une action de fusion. Valeurs valides : `simple`, `custom`. S'il la valeur est `simple`, le comportement de fusion est défini par `MergeWhenMatched` et `MergeWhenNotMatched`. Si la valeur est personnalisée, il est défini par `MergeClause`.

- **MergeWhenMatched** – Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Indique comment résoudre les enregistrements qui correspondent à des données préexistantes lors de la fusion. Valeurs valides : `update`, `delete`.

- **MergeWhenNotMatched** – Chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Indique comment traiter les enregistrements qui ne correspondent pas aux données préexistantes lors de la fusion. Valeurs valides : `insert`, `none`.

- **MergeClause** – Chaîne UTF-8.

Une instruction SQL qui spécifie un comportement de fusion personnalisé.

- **StagingTable** – Chaîne UTF-8.

Le nom d'une table intermédiaire utilisée lors de l'exécution de l'action `merge` ou d'actions d'insertion `append`. Les données sont écrites dans cette table, puis déplacées vers table par une postaction générée.

- **SelectedColumns** – Un tableau d'objets [Option](#).

Indique les colonnes combinées pour identifier un enregistrement lors de la détection des correspondances pour les fusions et les insertions. Une liste de structures avec des clés `value`, `label` et `description`. Chaque structure décrit une colonne.

- `AutoPushdown` – Booléen.

Indique si le pushdown automatique des requêtes est activée. Lorsque l'option pushdown est activée, si une partie de la requête peut être « poussée vers le bas » sur le serveur Snowflake, elle est poussée vers le bas au moment de l'exécution de la requête sur Spark. Cela améliore les performances de certaines requêtes.

- `TableSchema` – Un tableau d'objets [Option](#).

Définit manuellement le schéma cible du nœud. Une liste de structures avec des clés `value`, `label` et `description`. Chaque structure définit une colonne.

SnowflakeSource structure

Indique une source de données Snowflake.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la source de données Snowflake.

- `Data` – Obligatoire : un objet [SnowflakeNodeData](#).

Configuration de la source de données Snowflake.

- `OutputSchemas` – Un tableau d'objets [GlueSchema](#).

Indique les schémas définis par l'utilisateur pour vos données de sortie.

SnowflakeTarget structure

Indique une cible Snowflake.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Le nom de la cible Snowflake.

- Data – Obligatoire : un objet [SnowflakeNodeData](#).

Indique les données du nœud cible Snowflake.

- Inputs : tableau de chaînes UTF-8, avec une chaîne minimum et une chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

ConnectorDataSource structure

Spécifie une source générée avec des options de connexion standard.

Champs

- Name – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de ce nœud source.

- ConnectionType – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

LeconnectionType, tel que fourni à la AWS Glue bibliothèque sous-jacente. Ce type de nœud prend en charge les types de connexion suivants :

- opensearch
- azuresql
- azurecosmos
- bigquery
- saphana
- teradata
- vertica
- Data – obligatoire : tableau de mappage de paires clé-valeur.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Carte indiquant des options de connexion pour le nœud. Vous trouverez les options de connexion standard pour le type de connexion correspondant dans la section [Paramètres de connexion](#) de la AWS Glue documentation.

- OutputSchemas – Un tableau d'objets [GlueSchema](#).

Spécifie le schéma de données pour cette source.

ConnectorDataTarget structure

Spécifie une cible générée avec des options de connexion standard.

Champs

- Name – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #61](#).

Nom de ce nœud cible.

- ConnectionType – Obligatoire : Chaîne UTF-8, correspondant au [Custom string pattern #59](#).

LeconnectionType, tel que fourni à la AWS Glue bibliothèque sous-jacente. Ce type de nœud prend en charge les types de connexion suivants :

- opensearch
 - azuresql
 - azurecosmos
 - bigquery
 - saphana
 - teradata
 - vertica
- Data – obligatoire : tableau de mappage de paires clé-valeur.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Carte indiquant des options de connexion pour le nœud. Vous trouverez les options de connexion standard pour le type de connexion correspondant dans la section [Paramètres de connexion](#) de la AWS Glue documentation.

- **Inputs** : tableau de chaînes UTF-8, avec une chaîne minimum et une chaîne maximum.

Les nœuds qui constituent des entrées pour la cible de données.

RecipeStep structure

Étape de recette utilisée dans un nœud de recette de préparation de données AWS Glue Studio.

Champs

- **Action** – Obligatoire : un objet [RecipeAction](#).

L'action de transformation de l'étape de recette.

- **ConditionExpressions** – Un tableau d'objets [ConditionExpression](#).

Les expressions de condition pour l'étape de la recette.

RecipeAction structure

Actions définies dans le nœud de recette de préparation des données de AWS Glue Studio.

Champs

- **Operation** – obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #54](#).

Fonctionnement de l'action de recette.

- **Parameters** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #55](#).

Chaque valeur est une chaîne UTF-8 dont la longueur ne doit pas être inférieure à 1 ni supérieure à 32 768 octets.

Les paramètres de l'action de recette.

ConditionExpression structure

Expression de condition définie dans le nœud de recette de préparation des données de AWS Glue Studio.

Champs

- **Condition** – obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #54](#).

La condition de l'expression de la condition.

- **Value**— Chaîne UTF-8 d'une longueur maximale de 1024 octets.

Valeur de l'expression de condition.

- **TargetColumn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de 1 024 octets.

La colonne cible des expressions de condition.

API de tâches

L'API Jobs décrit les types de données des tâches et contient des informations APIs permettant d'utiliser les tâches, les exécutions de tâches et les déclencheurs AWS Glue.

Rubriques

- [Tâches](#)
- [Exécutions de tâches](#)
- [Déclencheurs](#)

Tâches

L'API Jobs décrit les types de données et l'API liés à la création, à la mise à jour, à la suppression ou à l'affichage des jobs dans AWS Glue.

Types de données

- [Structure Job](#)
- [ExecutionProperty structure](#)

- [NotificationProperty structure](#)
- [JobCommand structure](#)
- [ConnectionsList structure](#)
- [JobUpdate structure](#)
- [SourceControlDetails structure](#)

Structure Job

Spécifie une définition de la tâche.

Champs

- Name – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom que vous affectez à la définition de la tâche.

- JobMode – Chaîne UTF-8 (valeurs valides : SCRIPT="" | VISUAL="" | NOTEBOOK="").

Mode qui décrit la façon dont une tâche a été créée. Les valeurs valides sont :

- SCRIPT- La tâche a été créée à l'aide de l'éditeur de script AWS Glue Studio.
- VISUAL- La tâche a été créée à l'aide de l'éditeur visuel AWS Glue Studio.
- NOTEBOOK- Le job a été créé à l'aide d'un carnet de sessions interactif.

Lorsque le JobMode champ est manquant ou nul, SCRIPT il est attribué comme valeur par défaut.

- JobRunQueuingEnabled – Booléen.

Spécifie si la mise en file d'attente des tâches est activée pour les tâches exécutées pour cette tâche.

La valeur true signifie que la mise en file d'attente des tâches est activée pour les exécutions de tâches. S'il est faux ou s'il n'est pas renseigné, les exécutions de tâches ne seront pas prises en compte pour la mise en file d'attente.

Si ce champ ne correspond pas à la valeur définie lors de l'exécution du travail, la valeur du champ d'exécution du travail sera utilisée.

- Description – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la tâche.

- `LogUri` – Chaîne UTF-8.

Ce champ est réservé pour un usage futur.

- `Role` – Chaîne UTF-8.

Nom ou Amazon Resource Name (ARN) du rôle IAM associé à cette tâche.

- `CreatedOn` – Horodatage.

Date et heure de création de la définition de tâche.

- `LastModifiedOn` – Horodatage.

Dernier moment où la définition de tâche a été modifiée.

- `ExecutionProperty` – Un objet [ExecutionProperty](#).

Objet `ExecutionProperty` spécifiant le nombre maximal d'exécutions simultanées autorisées pour cette tâche.

- `Command` – Un objet [JobCommand](#).

La commande `JobCommand` qui exécute cette tâche.

- `DefaultArguments` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Les arguments par défaut pour chaque exécution de cette tâche, spécifiés en tant que paires nom-valeur.

Vous pouvez spécifier ici les arguments que votre propre script d'exécution de tâches consomme, ainsi que les arguments qu'il consomme AWS Glue lui-même.

Les arguments de la tâche peuvent être consignés. Ne transmettez pas de secrets en texte clair comme arguments. Récupérez les secrets d'une AWS Glue connexion AWS Secrets Manager ou d'un autre mécanisme de gestion des secrets si vous avez l'intention de les conserver dans le cadre du Job.

Pour plus d'informations sur la façon de spécifier et d'utiliser vos propres arguments Job, consultez la rubrique [Calling AWS Glue APIs in Python](#) du guide du développeur.

Pour plus d'informations sur les arguments que vous pouvez fournir dans ce champ lors de la configuration des tâches Spark, consultez la rubrique [Special Parameters Used by AWS Glue](#) dans le guide du développeur.

Pour plus d'informations sur les arguments que vous pouvez fournir dans ce champ lors de la configuration des tâches Ray, consultez [Utilisation des paramètres de tâches dans les tâches Ray](#) dans le guide du développeur.

- `NonOverridableArguments` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Les arguments de cette tâche qui ne sont pas remplacés lorsque vous fournissez des arguments de tâche dans le cadre d'une exécution de tâche, spécifiés sous forme de paires nom-valeur.

- `Connections` – Un objet [ConnectionsList](#).

Connexions utilisées pour la tâche.

- `MaxRetries` – Nombre (entier).

Nombre maximal de fois que vous pouvez réessayer cette tâche après un JobRun échec.

- `AllocatedCapacity` – Nombre (entier).

Ce champ est obsolète. Utilisez `MaxCapacity` à la place.

Nombre d'unités de traitement de AWS Glue données (DPUs) allouées aux exécutions de cette tâche. Vous pouvez en allouer au moins 2 DPUs ; la valeur par défaut est 10. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

- `Timeout` – Nombre (entier), au moins égal à 1.

Délai d'expiration de la tâche en minutes. Durée maximale durant laquelle une tâche exécutée peut consommer des ressources avant qu'elle ne se termine et n'entre dans l'état TIMEOUT.

Les délais d'expiration des tâches doivent être inférieurs à 7 jours ou 10080 minutes. Dans le cas contraire, les tâches généreront une exception.

Lorsque la valeur est laissée vide, le délai d'expiration est défini par défaut à 2880 minutes.

Toutes les AWS Glue tâches existantes dont le délai d'expiration est supérieur à 7 jours seront définies par défaut sur 7 jours. Par exemple, si vous avez spécifié un délai d'expiration de 20 jours pour un traitement par lots, celui-ci sera arrêté le 7ème jour.

Pour les tâches de streaming, si vous avez défini une fenêtre de maintenance, celle-ci sera redémarrée pendant la fenêtre de maintenance après 7 jours.

- `MaxCapacity` – Nombre (double).

Pour les tâches Glue version 1.0 ou antérieures, en utilisant le type de travailleur standard, le nombre d'unités de traitement des AWS Glue données (DPUs) pouvant être allouées lors de l'exécution de cette tâche. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

Pour les tâches des versions 2.0 ou ultérieures de Glue, vous ne pouvez pas spécifier de `Maximum capacity`. Au lieu de cela, vous devez spécifier `Worker type` et `Number of workers`.

Ne définissez pas `MaxCapacity` si vous utilisez `WorkerType` et `NumberOfWorkers`.

La valeur pouvant être attribuée à `MaxCapacity` varie selon que vous exécutez une tâche shell Python, une tâche ETL Apache Spark ou une tâche ETL Apache Spark Streaming :

- Lorsque vous spécifiez une tâche shell Python (`JobCommand.Name="pythonshell"`), vous pouvez allouer 0,0625 ou 1 DPU. La valeur par défaut correspond à 0,0625 DPU.
- Lorsque vous spécifiez une tâche ETL Apache Spark (`JobCommand.Name="glueetl »`) ou une tâche ETL de streaming Apache Spark (`JobCommand.Name="gluestreaming »`), vous pouvez en allouer de 2 à 100. DPUs La valeur par défaut est 10 DPUs. Ce type de tâche ne peut pas avoir une allocation DPU fractionnée.
- `WorkerType` – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type de travail prédéfini qui est alloué lorsqu'une tâche est exécutée. Accepte une valeur de `G.1X`, `G.2X`, `G.4X`, `G.8X` ou `G.025X` pour les tâches Spark. Accepte la valeur `Z.2X` pour les tâches Ray.

- Pour le type de G.1X worker, chaque worker est mappé à 1 DPU (4 vCPUs, 16 Go de mémoire) avec un disque de 94 Go, et fournit 1 exécuteur par worker. Nous recommandons ce type de travailleur pour les charges de travail telles que les transformations de données, les jointures et les requêtes, afin de proposer un moyen évolutif et rentable d'exécuter la plupart des tâches.
- Pour le type de G.2X travailleur, chaque utilisateur est mappé sur 2 DPU (8 VCPUs, 32 Go de mémoire) avec un disque de 138 Go et fournit un exécuteur par travailleur. Nous recommandons ce type de travailleur pour les charges de travail telles que les transformations de données, les jointures et les requêtes, afin de proposer un moyen évolutif et rentable d'exécuter la plupart des tâches.
- Pour le type de G.4X worker, chaque worker est mappé sur 4 DPU (16 vCPUs, 64 Go de mémoire) avec un disque de 256 Go, et fournit 1 exécuteur par worker. Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes. Ce type de travailleur est disponible uniquement pour les tâches Spark ETL AWS Glue version 3.0 ou ultérieure dans les AWS régions suivantes : USA Est (Ohio), USA Est (Virginie du Nord), USA Ouest (Californie du Nord), USA Ouest (Oregon), Asie-Pacifique (Mumbai), Asie-Pacifique (Séoul), Asie-Pacifique (Sydney), Asie-Pacifique (Tokyo), Canada (Centre), Europe (Francfort), Europe (Irlande), Europe (Londres), Europe (Espagne), Europe (Stockholm) et Amérique du Sud (São Paulo).
- Pour le type de G.8X travailleur, chaque travailleur est mappé sur 8 DPU (32 vCPUs, 128 Go de mémoire) avec un disque de 512 Go et fournit un exécuteur par travailleur. Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes. Ce type de travailleur n'est disponible que pour les tâches Spark ETL de AWS Glue version 3.0 ou ultérieure, dans les mêmes AWS régions que celles prises en charge pour le type de G.4X travailleur.
- Pour le type de G.025X worker, chaque worker est mappé sur 0,25 DPU (2 vCPUs, 4 Go de mémoire) avec un disque de 84 Go, et fournit 1 exécuteur par worker. Nous recommandons ce type d'employé pour les travaux de streaming à faible volume. Ce type de travailleur n'est disponible que pour les tâches de streaming en AWS Glue version 3.0 ou ultérieure.
- Pour le type de Z.2X travailleur, chaque utilisateur est mappé sur 2 M-DPU (8 VCPUs, 64 Go de mémoire) avec un disque de 128 Go et fournit jusqu'à 8 processeurs de rayons sur la base de l'autoscaler.
- `NumberOfWorkers` – Nombre (entier).

Nombre de travaux d'un `workerType` défini qui sont attribués lorsqu'une tâche est exécutée.

- **SecurityConfiguration** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la structure **SecurityConfiguration** à utiliser avec cette tâche.

- **NotificationProperty** – Un objet [NotificationProperty](#).

Spécifie les propriétés de configuration d'une notification de tâche.

- **Running** – Booléen.

Ce champ est réservé pour un usage futur.

- **GlueVersion** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

Dans les tâches Spark, **GlueVersion** détermine les versions d'Apache Spark et de Python AWS Glue disponibles dans une tâche. La version de Python indique la version prise en charge pour les tâches de type Spark.

Les tâches Ray doivent définir **GlueVersion** sur 4.0 ou supérieur. Toutefois, les versions de Ray, de Python et des bibliothèques supplémentaires disponibles dans votre tâche Ray sont déterminées par le paramètre **Runtime** de la commande de tâche.

Pour plus d'informations sur les AWS Glue versions disponibles et les versions correspondantes de Spark et Python, consultez [la version de Glue](#) dans le guide du développeur.

Les tâches créées sans que la version de Glue soit spécifiée sont des tâches Glue 0.9 par défaut.

- **CodeGenConfigurationNodes** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Chaque valeur est un objet [CodeGenConfigurationNode](#).

Représentation d'un graphe orienté acyclique sur lequel le composant visuel Glue Studio et la génération de code Glue Studio sont basés.

- **ExecutionClass** – Chaîne UTF-8, d'une longueur maximale de 16 octets (valeurs valides : FLEX="" | STANDARD="").

Indique si la tâche est exécutée avec une classe d'exécution standard ou flexible. La classe d'exécution standard est idéale pour les charges de travail sensibles au temps qui nécessitent un démarrage rapide des tâches et des ressources dédiées.

La classe d'exécution flexible, adaptée aux tâches non urgentes dont les heures de début et de fin peuvent varier.

Seules les tâches dotées de AWS Glue la version 3.0 ou supérieure et du type de commande `glueetl` seront autorisées à être définies `ExecutionClass` sur `FLEX`. La classe d'exécution flexible est disponible pour les tâches Spark.

- `SourceControlDetails` – Un objet [SourceControlDetails](#).

Les détails d'une configuration de contrôle source pour une tâche, permettant la synchronisation des artefacts de la tâche vers ou depuis un référentiel distant.

- `MaintenanceWindow` – Chaîne UTF-8, correspondant au [Custom string pattern #34](#).

Ce champ indique un jour de la semaine et une heure pour une fenêtre de maintenance pour les tâches de streaming. AWS Glue effectue périodiquement des activités de maintenance. Au cours de ces fenêtres de maintenance, vous AWS Glue devrez redémarrer vos tâches de streaming.

AWS Glue redémarrera le travail dans les 3 heures suivant la période de maintenance spécifiée. Par exemple, si vous configurez la fenêtre de maintenance pour le lundi à 10 h 00 GMT, vos tâches seront redémarrées entre 10 h 00 GMT et 13 h 00 GMT.

- `ProfileName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom d'un profil AWS Glue d'utilisation associé à la tâche.

ExecutionProperty structure

Propriété d'exécution d'une tâche.

Champs

- `MaxConcurrentRuns` – Nombre (entier).

Nombre maximal d'exécutions simultanées autorisées pour la tâche. La valeur par défaut est 1. Une erreur est renvoyée lorsque ce seuil est atteint. La valeur maximale que vous pouvez spécifier est contrôlée par une limite de service.

NotificationProperty structure

Spécifie les propriétés de configuration d'une notification.

Champs

- `NotifyDelayAfter` – Nombre (entier), au moins égal à 1.

Après le démarrage d'une exécution de tâche, nombre de minutes d'attente avant l'envoi d'une notification de délai d'exécution de tâche.

JobCommand structure

Spécifie le code exécuté lorsqu'une tâche est exécutée.

Champs

- `Name` – Chaîne UTF-8.

Nom de la commande de tâche. Pour une tâche ETL Apache Spark, cette valeur doit être `glueetl`. Pour un shell Python, elle doit être `pythonshell`. Pour une tâche ETL Apache Spark Streaming, elle doit correspondre à `gluestreaming`. Pour une tâche Ray, cela doit être `glueray`.

- `ScriptLocation` – Chaîne UTF-8, d'une longueur maximale de 400 000 octets.

Spécifie le chemin d'accès Amazon Simple Storage Service (Amazon S3) à un script qui exécute une tâche.

- `PythonVersion` – Chaîne UTF-8, correspondant au [Custom string pattern #48](#).

Version Python utilisée pour exécuter une tâche shell Python. Les valeurs autorisées sont 2 ou 3.

- `Runtime` : chaîne UTF-8, d'une longueur ne dépassant pas 64 octets, correspondant au [Custom string pattern #33](#).

Dans les tâches Ray, l'exécution est utilisée pour spécifier les versions de Ray, de Python et des bibliothèques supplémentaires disponibles dans votre environnement. Ce champ n'est pas utilisé dans les autres types de tâches. Pour connaître les valeurs d'environnement d'exécution prises [en charge, consultez la section Environnements d'exécution Ray pris en charge](#) dans le manuel du AWS Glue développeur.

ConnectionsList structure

Spécifie les connexions utilisées par une tâche.

Champs

- **Connections**— Un tableau de chaînes UTF-8 ne dépassant pas 1 000 chaînes.

Liste de connexions utilisées par la tâche.

JobUpdate structure

Spécifie les informations utilisées pour mettre à jour une définition de tâche. La définition de tâche précédente est entièrement remplacée par ces informations.

Champs

- **JobMode** – Chaîne UTF-8 (valeurs valides : `SCRIPT=""` | `VISUAL=""` | `NOTEBOOK=""`).

Mode qui décrit la façon dont une tâche a été créée. Les valeurs valides sont :

- **SCRIPT**- La tâche a été créée à l'aide de l'éditeur de script AWS Glue Studio.
- **VISUAL**- La tâche a été créée à l'aide de l'éditeur visuel AWS Glue Studio.
- **NOTEBOOK**- Le job a été créé à l'aide d'un carnet de sessions interactif.

Lorsque le JobMode champ est manquant ou nul, `SCRIPT` il est attribué comme valeur par défaut.

- **JobRunQueuingEnabled** – Booléen.

Spécifie si la mise en file d'attente des tâches est activée pour les tâches exécutées pour cette tâche.

La valeur `true` signifie que la mise en file d'attente des tâches est activée pour les exécutions de tâches. S'il est faux ou s'il n'est pas renseigné, les exécutions de tâches ne seront pas prises en compte pour la mise en file d'attente.

Si ce champ ne correspond pas à la valeur définie lors de l'exécution du travail, la valeur du champ d'exécution du travail sera utilisée.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la tâche définie.

- `LogUri` – Chaîne UTF-8.

Ce champ est réservé pour un usage futur.

- `Role` – Chaîne UTF-8.

Nom ou Amazon Resource Name (ARN) du rôle IAM associé à cette tâche (obligatoire).

- `ExecutionProperty` – Un objet [ExecutionProperty](#).

Objet `ExecutionProperty` spécifiant le nombre maximal d'exécutions simultanées autorisées pour cette tâche.

- `Command` – Un objet [JobCommand](#).

Objet `JobCommand` qui exécute cette tâche (obligatoire).

- `DefaultArguments` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Les arguments par défaut pour chaque exécution de cette tâche, spécifiés en tant que paires nom-valeur.

Vous pouvez spécifier ici les arguments que votre propre script d'exécution de tâches consomme, ainsi que les arguments qu'il consomme AWS Glue lui-même.

Les arguments de la tâche peuvent être consignés. Ne transmettez pas de secrets en texte clair comme arguments. Récupérez les secrets d'une AWS Glue connexion AWS Secrets Manager ou d'un autre mécanisme de gestion des secrets si vous avez l'intention de les conserver dans le cadre du Job.

Pour plus d'informations sur la façon de spécifier et d'utiliser vos propres arguments Job, consultez la rubrique [Calling AWS Glue APIs in Python](#) du guide du développeur.

Pour plus d'informations sur les arguments que vous pouvez fournir dans ce champ lors de la configuration des tâches Spark, consultez la rubrique [Special Parameters Used by AWS Glue](#) dans le guide du développeur.

Pour plus d'informations sur les arguments que vous pouvez fournir dans ce champ lors de la configuration des tâches Ray, consultez [Utilisation des paramètres de tâches dans les tâches Ray](#) dans le guide du développeur.

- `NonOverridableArguments` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Les arguments de cette tâche qui ne sont pas remplacés lorsque vous fournissez des arguments de tâche dans le cadre d'une exécution de tâche, spécifiés sous forme de paires nom-valeur.

- `Connections` – Un objet [ConnectionsList](#).

Connexions utilisées pour la tâche.

- `MaxRetries` – Nombre (entier).

Nombre maximum de tentatives de cette tâche en cas d'échec.

- `AllocatedCapacity` – Nombre (entier).

Ce champ est obsolète. Utilisez `MaxCapacity` à la place.

Le nombre d'unités de traitement de AWS Glue données (DPU) à allouer à cette tâche. Vous pouvez en allouer au moins 2 DPUs ; la valeur par défaut est 10. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

- `Timeout` – Nombre (entier), au moins égal à 1.

Délai d'expiration de la tâche en minutes. Durée maximale durant laquelle une tâche exécutée peut consommer des ressources avant qu'elle ne se termine et n'entre dans l'état `TIMEOUT`.

Les délais d'expiration des tâches doivent être inférieurs à 7 jours ou 10080 minutes. Dans le cas contraire, les tâches généreront une exception.

Lorsque la valeur est laissée vide, le délai d'expiration est défini par défaut à 2880 minutes.

Toutes les AWS Glue tâches existantes dont le délai d'expiration est supérieur à 7 jours seront définies par défaut sur 7 jours. Par exemple, si vous avez spécifié un délai d'expiration de 20 jours pour un traitement par lots, celui-ci sera arrêté le 7ème jour.

Pour les tâches de streaming, si vous avez défini une fenêtre de maintenance, celle-ci sera redémarrée pendant la fenêtre de maintenance après 7 jours.

- `MaxCapacity` – Nombre (double).

Pour les tâches Glue version 1.0 ou antérieures, en utilisant le type de travailleur standard, le nombre d'unités de traitement des AWS Glue données (DPUs) pouvant être allouées lors de l'exécution de cette tâche. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

Pour les tâches des versions 2.0 et ultérieures de Glue, vous ne pouvez pas spécifier un `Maximum capacity`. Au lieu de cela, vous devez spécifier `Worker type` et `Number of workers`.

Ne définissez pas `MaxCapacity` si vous utilisez `WorkerType` et `NumberOfWorkers`.

La valeur pouvant être attribuée à `MaxCapacity` varie selon que vous exécutez une tâche shell Python, une tâche ETL Apache Spark ou une tâche ETL Apache Spark Streaming :

- Lorsque vous spécifiez une tâche shell Python (`JobCommand.Name="pythonshell"`), vous pouvez allouer 0,0625 ou 1 DPU. La valeur par défaut correspond à 0,0625 DPU.
- Lorsque vous spécifiez une tâche ETL Apache Spark (`JobCommand.Name="glueetl »`) ou une tâche ETL de streaming Apache Spark (`JobCommand.Name="gluestreaming »`), vous pouvez en allouer de 2 à 100. DPUs La valeur par défaut est 10 DPUs. Ce type de tâche ne peut pas avoir une allocation DPU fractionnée.
- `WorkerType` – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type de travail prédéfini qui est alloué lorsqu'une tâche est exécutée. Accepte une valeur de `G.1X`, `G.2X`, `G.4X`, `G.8X` ou `G.025X` pour les tâches Spark. Accepte la valeur `Z.2X` pour les tâches Ray. Pour plus d'informations, consultez [la section Définition des propriétés des tâches Spark](#)

- `NumberOfWorkers` – Nombre (entier).

Nombre de travaux d'un `workerType` défini qui sont attribués lorsqu'une tâche est exécutée.

- `SecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la structure `SecurityConfiguration` à utiliser avec cette tâche.

- `NotificationProperty` – Un objet [NotificationProperty](#).

Spécifie les propriétés de configuration d'une notification de tâche.

- `GlueVersion` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

Dans les tâches Spark, GlueVersion détermine les versions d'Apache Spark et de Python AWS Glue disponibles dans une tâche. La version de Python indique la version prise en charge pour les tâches de type Spark.

Les tâches Ray doivent définir GlueVersion sur 4.0 ou supérieur. Toutefois, les versions de Ray, de Python et des bibliothèques supplémentaires disponibles dans votre tâche Ray sont déterminées par le paramètre Runtime de la commande de tâche.

Pour plus d'informations sur les AWS Glue versions disponibles et les versions correspondantes de Spark et Python, consultez [la version de Glue](#) dans le guide du développeur.

Les tâches créées sans que la version de Glue soit spécifiée sont des tâches Glue 0.9 par défaut.

- `CodeGenConfigurationNodes` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Chaque valeur est un objet [CodeGenConfigurationNode](#).

Représentation d'un graphe orienté acyclique sur lequel le composant visuel Glue Studio et la génération de code Glue Studio sont basés.

- `ExecutionClass` – Chaîne UTF-8, d'une longueur maximale de 16 octets (valeurs valides : `FLEX=""` | `STANDARD=""`).

Indique si la tâche est exécutée avec une classe d'exécution standard ou flexible. La classe d'exécution standard est idéale pour les charges de travail urgentes qui nécessitent un démarrage rapide des tâches et des ressources dédiées.

La classe d'exécution flexible, adaptée aux tâches non urgentes dont les heures de début et de fin peuvent varier.

Seules les tâches dotées de AWS Glue la version 3.0 ou supérieure et du type de commande `glueetl` seront autorisées à être définies `ExecutionClass` sur `FLEX`. La classe d'exécution flexible est disponible pour les tâches Spark.

- `SourceControlDetails` – Un objet [SourceControlDetails](#).

Les détails d'une configuration de contrôle source pour une tâche, permettant la synchronisation des artefacts de la tâche vers ou depuis un référentiel distant.

- `MaintenanceWindow` – Chaîne UTF-8, correspondant au [Custom string pattern #34](#).

Ce champ indique un jour de la semaine et une heure pour une fenêtre de maintenance pour les tâches de streaming. AWS Glue effectue périodiquement des activités de maintenance. Au cours de ces fenêtres de maintenance, vous AWS Glue devrez redémarrer vos tâches de streaming.

AWS Glue redémarrera le travail dans les 3 heures suivant la période de maintenance spécifiée. Par exemple, si vous configurez la fenêtre de maintenance pour le lundi à 10 h 00 GMT, vos tâches seront redémarrées entre 10 h 00 GMT et 13 h 00 GMT.

- `ProfileName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom d'un profil AWS Glue d'utilisation associé à la tâche.

SourceControlDetails structure

Les détails d'une configuration de contrôle source pour une tâche, permettant la synchronisation des artefacts de la tâche vers ou depuis un référentiel distant.

Champs

- `Provider` – Chaîne UTF-8 (valeurs valides : GITHUB | AWS_CODE_COMMIT).

Le fournisseur du référentiel distant.

- `Repository` – chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets.

Le nom du référentiel distant qui contient les artefacts de la tâche.

- `Owner` – chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets.

Le propriétaire du référentiel distant qui contient les artefacts de la tâche.

- `Branch` – chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets.

Une branche facultative dans le référentiel distant.

- `Folder` – chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets.

Un dossier facultatif dans le référentiel distant.

- `LastCommitId` – chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets.

Le dernier identifiant de validation pour une validation dans le référentiel distant.

- `LastSyncTimestamp` – chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets.

La date et l'heure auxquelles la dernière synchronisation de la tâche a été effectuée.

- `AuthStrategy` – Chaîne UTF-8 (valeurs valides : `PERSONAL_ACCESS_TOKEN` | `AWS_SECRETS_MANAGER`).

Le type d'authentification, qui peut être un jeton d'authentification stocké dans AWS Secrets Manager ou un jeton d'accès personnel.

- `AuthToken` – chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets.

La valeur d'un jeton d'autorisation.

Opérations

- [CreateJob action \(Python : `create\_job`\)](#)
- [UpdateJob action \(Python : `update\_job`\)](#)
- [GetJob action \(Python : `get\_job`\)](#)
- [GetJobs action \(Python : `get\_jobs`\)](#)
- [DeleteJob action \(Python : `supprimer\_tâche`\)](#)
- [ListJobs action \(Python : `list\_jobs`\)](#)
- [BatchGetJobs action \(Python : `batch\_get\_jobs`\)](#)

CreateJob action (Python : `create_job`)

Crée une nouvelle définition de tâche.

Demande

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom que vous affectez à la définition de la tâche. Doit être unique au sein de votre compte .

- `JobMode` – Chaîne UTF-8 (valeurs valides : `SCRIPT=""` | `VISUAL=""` | `NOTEBOOK=""`).

Mode qui décrit la façon dont une tâche a été créée. Les valeurs valides sont :

- `SCRIPT`- La tâche a été créée à l'aide de l'éditeur de script AWS Glue Studio.
- `VISUAL`- La tâche a été créée à l'aide de l'éditeur visuel AWS Glue Studio.

- NOTEB00K- Le job a été créé à l'aide d'un carnet de sessions interactif.

Lorsque le JobMode champ est manquant ou nul, SCRIPT il est attribué comme valeur par défaut.

- JobRunQueuingEnabled – Booléen.

Spécifie si la mise en file d'attente des tâches est activée pour les tâches exécutées pour cette tâche.

La valeur true signifie que la mise en file d'attente des tâches est activée pour les exécutions de tâches. S'il est faux ou s'il n'est pas renseigné, les exécutions de tâches ne seront pas prises en compte pour la mise en file d'attente.

Si ce champ ne correspond pas à la valeur définie lors de l'exécution du travail, la valeur du champ d'exécution du travail sera utilisée.

- Description – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la tâche définie.

- LogUri – Chaîne UTF-8.

Ce champ est réservé pour un usage futur.

- Role – Obligatoire : chaîne UTF-8.

Nom ou Amazon Resource Name (ARN) du rôle IAM associé à cette tâche.

- ExecutionProperty – Un objet [ExecutionProperty](#).

Objet ExecutionProperty spécifiant le nombre maximal d'exécutions simultanées autorisées pour cette tâche.

- Command – Obligatoire : un objet [JobCommand](#).

La commande JobCommand qui exécute cette tâche.

- DefaultArguments – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Les arguments par défaut pour chaque exécution de cette tâche, spécifiés en tant que paires nom-valeur.

Vous pouvez spécifier ici les arguments que votre propre script d'exécution de tâches consomme, ainsi que les arguments qu'il consomme AWS Glue lui-même.

Les arguments de la tâche peuvent être consignés. Ne transmettez pas de secrets en texte clair comme arguments. Récupérez les secrets d'une AWS Glue connexion AWS Secrets Manager ou d'un autre mécanisme de gestion des secrets si vous avez l'intention de les conserver dans le cadre du Job.

Pour plus d'informations sur la façon de spécifier et d'utiliser vos propres arguments Job, consultez la rubrique [Calling AWS Glue APIs in Python](#) du guide du développeur.

Pour plus d'informations sur les arguments que vous pouvez fournir dans ce champ lors de la configuration des tâches Spark, consultez la rubrique [Special Parameters Used by AWS Glue](#) dans le guide du développeur.

Pour plus d'informations sur les arguments que vous pouvez fournir dans ce champ lors de la configuration des tâches Ray, consultez [Utilisation des paramètres de tâches dans les tâches Ray](#) dans le guide du développeur.

- `NonOverridableArguments` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Les arguments de cette tâche qui ne sont pas remplacés lorsque vous fournissez des arguments de tâche dans le cadre d'une exécution de tâche, spécifiés sous forme de paires nom-valeur.

- `Connections` – Un objet [ConnectionsList](#).

Connexions utilisées pour la tâche.

- `MaxRetries` – Nombre (entier).

Nombre maximum de tentatives de cette tâche en cas d'échec.

- `AllocatedCapacity` – Nombre (entier).

Ce paramètre est obsolète. Utilisez `MaxCapacity` à la place.

Le nombre d'unités de traitement de AWS Glue données (DPUs) à allouer à ce Job. Vous pouvez en allouer au moins 2 DPUs ; la valeur par défaut est 10. Un DPU est une mesure relative de la

puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

- **Timeout** – Nombre (entier), au moins égal à 1.

Délai d'expiration de la tâche en minutes. Durée maximale durant laquelle une tâche exécutée peut consommer des ressources avant qu'elle ne se termine et n'entre dans l'état TIMEOUT.

Les délais d'expiration des tâches doivent être inférieurs à 7 jours ou 10080 minutes. Dans le cas contraire, les tâches généreront une exception.

Lorsque la valeur est laissée vide, le délai d'expiration est défini par défaut à 2880 minutes.

Toutes les AWS Glue tâches existantes dont le délai d'expiration est supérieur à 7 jours seront définies par défaut sur 7 jours. Par exemple, si vous avez spécifié un délai d'expiration de 20 jours pour un traitement par lots, celui-ci sera arrêté le 7ème jour.

Pour les tâches de streaming, si vous avez défini une fenêtre de maintenance, celle-ci sera redémarrée pendant la fenêtre de maintenance après 7 jours.

- **MaxCapacity** – Nombre (double).

Pour les tâches Glue version 1.0 ou antérieures, en utilisant le type de travailleur standard, le nombre d'unités de traitement des AWS Glue données (DPUs) pouvant être allouées lors de l'exécution de cette tâche. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

Pour les tâches des versions 2.0 et ultérieures de Glue, vous ne pouvez pas spécifier un `Maximum capacity`. Au lieu de cela, vous devez spécifier `Worker type` et `Number of workers`.

Ne définissez pas `MaxCapacity` si vous utilisez `WorkerType` et `NumberOfWorkers`.

La valeur pouvant être attribuée à `MaxCapacity` varie selon que vous exécutez une tâche shell Python, une tâche ETL Apache Spark ou une tâche ETL Apache Spark Streaming :

- Lorsque vous spécifiez une tâche shell Python (`JobCommand.Name="pythonshell"`), vous pouvez allouer 0,0625 ou 1 DPU. La valeur par défaut correspond à 0,0625 DPU.
- Lorsque vous spécifiez une tâche ETL Apache Spark (`JobCommand.Name="glueetl"`) ou une tâche ETL de streaming Apache Spark (`JobCommand.Name="gluestreaming"`), vous pouvez en allouer de 2 à 100. DPUs La valeur par défaut est 10 DPUs. Ce type de tâche ne peut pas avoir une allocation DPU fractionnée.

- `SecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la structure `SecurityConfiguration` à utiliser avec cette tâche.

- `Tags` – tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Balises à utiliser avec cette tâche. Vous pouvez utiliser des balises pour limiter l'accès à la tâche. Pour plus d'informations sur les tags in AWS Glue, voir [AWS Tags in AWS Glue](#) dans le guide du développeur.

- `NotificationProperty` – Un objet [NotificationProperty](#).

Spécifie les propriétés de configuration d'une notification de tâche.

- `GlueVersion` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

Dans les tâches Spark, `GlueVersion` détermine les versions d'Apache Spark et de Python AWS Glue disponibles dans une tâche. La version de Python indique la version prise en charge pour les tâches de type Spark.

Les tâches Ray doivent définir `GlueVersion` sur 4.0 ou supérieur. Toutefois, les versions de Ray, de Python et des bibliothèques supplémentaires disponibles dans votre tâche Ray sont déterminées par le paramètre `Runtime` de la commande de tâche.

Pour plus d'informations sur les AWS Glue versions disponibles et les versions correspondantes de Spark et Python, consultez [la version de Glue](#) dans le guide du développeur.

Les tâches créées sans que la version de Glue soit spécifiée sont des tâches Glue 0.9 par défaut.

- `NumberOfWorkers` – Nombre (entier).

Nombre de travaux d'un `workerType` défini qui sont attribués lorsqu'une tâche est exécutée.

- `WorkerType` – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type de travail prédéfini qui est alloué lorsqu'une tâche est exécutée. Accepte une valeur de `G.1X`, `G.2X`, `G.4X`, `G.8X` ou `G.025X` pour les tâches Spark. Accepte la valeur `Z.2X` pour les tâches Ray.

- Pour le type de G.1X worker, chaque worker est mappé à 1 DPU (4 vCPUs, 16 Go de mémoire) avec un disque de 94 Go, et fournit 1 exécuteur par worker. Nous recommandons ce type de travailleur pour les charges de travail telles que les transformations de données, les jointures et les requêtes, afin de proposer un moyen évolutif et rentable d'exécuter la plupart des tâches.
- Pour le type de G.2X travailleur, chaque utilisateur est mappé sur 2 DPU (8 VCPUs, 32 Go de mémoire) avec un disque de 138 Go et fournit un exécuteur par travailleur. Nous recommandons ce type de travailleur pour les charges de travail telles que les transformations de données, les jointures et les requêtes, afin de proposer un moyen évolutif et rentable d'exécuter la plupart des tâches.
- Pour le type de G.4X worker, chaque worker est mappé sur 4 DPU (16 vCPUs, 64 Go de mémoire) avec un disque de 256 Go, et fournit 1 exécuteur par worker. Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes. Ce type de travailleur est disponible uniquement pour les tâches Spark ETL AWS Glue version 3.0 ou ultérieure dans les AWS régions suivantes : USA Est (Ohio), USA Est (Virginie du Nord), USA Ouest (Californie du Nord), USA Ouest (Oregon), Asie-Pacifique (Mumbai), Asie-Pacifique (Séoul), Asie-Pacifique (Sydney), Asie-Pacifique (Tokyo), Canada (Centre), Europe (Francfort), Europe (Irlande), Europe (Londres), Europe (Espagne), Europe (Stockholm) et Amérique du Sud (São Paulo).
- Pour le type de G.8X travailleur, chaque travailleur est mappé sur 8 DPU (32 vCPUs, 128 Go de mémoire) avec un disque de 512 Go et fournit un exécuteur par travailleur. Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes. Ce type de travailleur n'est disponible que pour les tâches Spark ETL de AWS Glue version 3.0 ou ultérieure, dans les mêmes AWS régions que celles prises en charge pour le type de G.4X travailleur.
- Pour le type de G.025X travailleur, chaque utilisateur est mappé sur 0,25 DPU (2 vCPUs, 4 Go de mémoire) avec un disque de 84 Go et fournit un exécuteur par programme de travail. Nous recommandons ce type d'employé pour les travaux de streaming à faible volume. Ce type de travailleur n'est disponible que pour les tâches de streaming en AWS Glue version 3.0 ou ultérieure.
- Pour le type de Z.2X travailleur, chaque utilisateur est mappé sur 2 M-DPU (8 VCPUs, 64 Go de mémoire) avec un disque de 128 Go et fournit jusqu'à 8 processeurs de rayons sur la base de l'autoscaler.
- CodeGenConfigurationNodes – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, correspondant au [Custom string pattern #58](#).

Chaque valeur est un objet [CodeGenConfigurationNode](#).

Représentation d'un graphe orienté acyclique sur lequel le composant visuel Glue Studio et la génération de code Glue Studio sont basés.

- `ExecutionClass` – Chaîne UTF-8, d'une longueur maximale de 16 octets (valeurs valides : `FLEX=""` | `STANDARD=""`).

Indique si la tâche est exécutée avec une classe d'exécution standard ou flexible. La classe d'exécution standard est idéale pour les charges de travail urgentes qui nécessitent un démarrage rapide des tâches et des ressources dédiées.

La classe d'exécution flexible, adaptée aux tâches non urgentes dont les heures de début et de fin peuvent varier.

Seules les tâches dotées de AWS Glue la version 3.0 ou supérieure et du type de commande `glueetl` seront autorisées à être définies `ExecutionClass` sur `FLEX`. La classe d'exécution flexible est disponible pour les tâches Spark.

- `SourceControlDetails` – Un objet [SourceControlDetails](#).

Les détails d'une configuration de contrôle source pour une tâche, permettant la synchronisation des artefacts de la tâche vers ou depuis un référentiel distant.

- `MaintenanceWindow` – Chaîne UTF-8, correspondant au [Custom string pattern #34](#).

Ce champ indique un jour de la semaine et une heure pour une fenêtre de maintenance pour les tâches de streaming. AWS Glue effectue périodiquement des activités de maintenance. Au cours de ces fenêtres de maintenance, vous AWS Glue devrez redémarrer vos tâches de streaming.

AWS Glue redémarrera le travail dans les 3 heures suivant la période de maintenance spécifiée. Par exemple, si vous configurez la fenêtre de maintenance pour le lundi à 10 h 00 GMT, vos tâches seront redémarrées entre 10 h 00 GMT et 13 h 00 GMT.

- `ProfileName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom d'un profil AWS Glue d'utilisation associé à la tâche.

Réponse

- Name – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom unique qui a été fourni pour cette définition de tâche.

Erreurs

- InvalidInputException
- IdempotentParameterMismatchException
- AlreadyExistsException
- InternalServiceException
- OperationTimeoutException
- ResourceNumberLimitExceededException
- ConcurrentModificationException

UpdateJob action (Python : update_job)

Met à jour une définition de tâche. La définition de tâche précédente est entièrement remplacée par ces informations.

Demande

- JobName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de tâche à mettre à jour.

- JobUpdate – Obligatoire : un objet [JobUpdate](#).

Spécifie les valeurs avec lesquelles mettre à jour la définition de la tâche. Toute configuration non spécifiée est supprimée ou réinitialisée aux valeurs par défaut.

- ProfileName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom d'un profil AWS Glue d'utilisation associé à la tâche.

Réponse

- JobName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Retourne le nom de la définition de tâche mise à jour.

Erreurs

- InvalidInputException
- EntityNotFoundException
- InternalServiceException
- OperationTimeoutException
- ConcurrentModificationException

GetJob action (Python : get_job)

Extrait une définition de tâche.

Demande

- JobName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de tâche à extraire.

Réponse

- Job – Un objet [Tâche](#).

Définition de tâche requise.

Erreurs

- InvalidInputException
- EntityNotFoundException
- InternalServiceException

- `OperationTimeoutException`

GetJobs action (Python : `get_jobs`)

Récupère toutes les définitions de tâche actuelles.

Demande

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Taille maximale de la réponse.

Réponse

- `Jobs` – Un tableau [Tâche](#) d'objets.

Liste des définitions de tâche.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, si toutes les définitions de tâche n'ont pas encore été renvoyées.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

DeleteJob action (Python : `supprimer_tâche`)

Supprime une définition de tâche spécifiée. Si la définition de tâche est introuvable, aucune exception n'est levée.

Demande

- JobName – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de tâche à supprimer.

Réponse

- JobName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de tâche qui a été supprimée.

Erreurs

- InvalidInputException
- InternalServiceException
- OperationTimeoutException

ListJobs action (Python : list_jobs)

Récupère les noms de toutes les ressources de travail de ce AWS compte ou des ressources portant le tag spécifié. Cette opération vous permet de voir quelles ressources sont disponibles dans votre compte, et leurs noms.

Cette opération accepte le champ Tags facultatif que vous pouvez utiliser comme filtre sur la réponse, afin que les ressources balisées puissent être récupérées en tant que groupe. Si vous choisissez d'utiliser le filtrage des balises, seules les ressources avec la balise sont récupérées.

Demande

- NextToken – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'une requête de continuation.

- MaxResults – Nombre (entier), compris entre 1 et 1 000.

La taille maximale d'une liste à renvoyer.

- **Tags** – tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Spécifie de renvoyer uniquement les ressources balisées.

Réponse

- **JobNames** – Tableau de chaînes UTF-8.

Noms de toutes les tâches dans le compte ou des tâches avec les balises spécifiées.

- **NextToken** – Chaîne UTF-8.

Jeton continuation, si la liste renvoyée ne contient pas la dernière métrique disponible.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

BatchGetJobs action (Python : `batch_get_jobs`)

Renvoie la liste des métadonnées de ressource pour une liste donnée de noms de tâche. Après avoir appelé l'opération `ListJobs`, vous pouvez appeler cette opération pour accéder aux données sur lesquelles des autorisations vous ont été octroyées. Cette opération prend en charge toutes les autorisations IAM, y compris les conditions d'autorisation qui utilisent des balises.

Demande

- **JobNames** – obligatoire : tableau de chaînes UTF-8.

Liste des noms de tâche, qui peuvent être les noms renvoyés à partir de l'opération `ListJobs`.

Réponse

- Jobs – Un tableau [Tâche](#) d'objets.

Liste des définitions de tâche.

- JobsNotFound – Tableau de chaînes UTF-8.

Liste de noms de tâches introuvables.

Erreurs

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Exécutions de tâches

L'API Jobs Runs décrit les types de données et l'API liés au démarrage, à l'arrêt ou à la visualisation des exécutions de tâches, ainsi qu'à la réinitialisation des signets de tâches, dans AWS Glue. L'historique d'exécution des tâches est accessible pendant 90 jours pour votre flux de travail et l'exécution des tâches.

Types de données

- [JobRun structure](#)
- [Structure de Predecessor](#)
- [JobBookmarkEntry structure](#)
- [BatchStopJobRunSuccessfulSubmission structure](#)
- [BatchStopJobRunError structure](#)
- [NotificationProperty structure](#)

JobRun structure

Contient des informations à propos d'une exécution de tâche.

Champs

- **Id** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de cette exécution de tâche.

- **Attempt** – Nombre (entier).

Nombre de tentatives d'exécution de cette tâche.

- **PreviousRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de l'exécution précédente de cette tâche. Par exemple, JobRunId spécifié dans l'action StartJobRun.

- **TriggerName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du déclencheur ayant démarré cette exécution de tâche.

- **JobName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de tâche utilisée dans cette exécution.

- **JobMode** – Chaîne UTF-8 (valeurs valides : SCRIPT="" | VISUAL="" | NOTEBOOK="").

Mode qui décrit la façon dont une tâche a été créée. Les valeurs valides sont :

- **SCRIPT**- La tâche a été créée à l'aide de l'éditeur de script AWS Glue Studio.
- **VISUAL**- La tâche a été créée à l'aide de l'éditeur visuel AWS Glue Studio.
- **NOTEBOOK**- Le job a été créé à l'aide d'un carnet de sessions interactif.

Lorsque le JobMode champ est manquant ou nul, SCRIPT il est attribué comme valeur par défaut.

- **JobRunQueuingEnabled** – Booléen.

Spécifie si la mise en file d'attente des tâches est activée pour l'exécution de la tâche.

La valeur true signifie que la mise en file d'attente des tâches est activée pour l'exécution de la tâche. Si la valeur est fausse ou si elle n'est pas renseignée, la tâche exécutée ne sera pas prise en compte pour la mise en file d'attente.

- **StartedOn** – Horodatage.

Date et heure auxquelles cette exécution de tâche a démarré.

- `LastModifiedOn` – Horodatage.

Heure de la dernière modification de cette exécution de tâche.

- `CompletedOn` – Horodatage.

Date et heure auxquelles cette exécution de tâche s'est terminée.

- `JobRunState`— Chaîne UTF-8 (valeurs valides : `STARTING` | `RUNNING` | `STOPPING` | `STOPPED` | `SUCCEEDED` | `FAILED` | `TIMEOUT` | `ERROR` | `WAITING` | `EXPIRED`).

État actuel de l'exécution de tâche. Pour plus d'informations sur les statuts des tâches qui se sont terminées anormalement, consultez [AWS Glue Job Run Statuses](#).

- `Arguments` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Arguments de la tâche associés à cette exécution. Pour cette exécution de tâche, ils remplacent les arguments par défaut définis pour la tâche elle-même.

Vous pouvez spécifier ici les arguments que votre propre script d'exécution de tâches consomme, ainsi que les arguments qu'il consomme AWS Glue lui-même.

Les arguments de la tâche peuvent être consignés. Ne transmettez pas de secrets en texte clair comme arguments. Récupérez les secrets d'une AWS Glue connexion AWS Secrets Manager ou d'un autre mécanisme de gestion des secrets si vous avez l'intention de les conserver dans le cadre du Job.

Pour plus d'informations sur la façon de spécifier et d'utiliser vos propres arguments Job, consultez la rubrique [Calling AWS Glue APIs in Python](#) du guide du développeur.

Pour plus d'informations sur les arguments que vous pouvez fournir dans ce champ lors de la configuration des tâches Spark, consultez la rubrique [Special Parameters Used by AWS Glue](#) dans le guide du développeur.

Pour plus d'informations sur les arguments que vous pouvez fournir dans ce champ lors de la configuration des tâches Ray, consultez [Utilisation des paramètres de tâches dans les tâches Ray](#) dans le guide du développeur.

- `ErrorMessage` – Chaîne UTF-8.

Message d'erreur associé à cette exécution de tâche.

- `PredecessorRuns` – Un tableau d'objets [Predecessor](#).

Liste des prédécesseurs de cette exécution de tâche.

- `AllocatedCapacity` – Nombre (entier).

Ce champ est obsolète. Utilisez `MaxCapacity` à la place.

Le nombre d'unités de traitement de AWS Glue données (DPUs) qui y sont allouées `JobRun`. De 2 à 100 DPUs peuvent être alloués ; la valeur par défaut est 10. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

- `ExecutionTime` – Nombre (entier).

Durée (en secondes) pendant laquelle la tâche exécutée a consommé des ressources.

- `Timeout` – Nombre (entier), au moins égal à 1.

Délai d'expiration de `JobRun` en minutes. Durée maximale durant laquelle une tâche exécutée peut consommer des ressources avant qu'elle ne se termine et n'entre dans l'état `TIMEOUT`. Cette valeur remplace la valeur définie dans la tâche parent.

Les délais d'expiration des tâches doivent être inférieurs à 7 jours ou 10080 minutes. Dans le cas contraire, les tâches généreront une exception.

Lorsque la valeur est laissée vide, le délai d'expiration est défini par défaut à 2880 minutes.

Toutes les AWS Glue tâches existantes dont le délai d'expiration est supérieur à 7 jours seront définies par défaut sur 7 jours. Par exemple, si vous avez spécifié un délai d'expiration de 20 jours pour un traitement par lots, celui-ci sera arrêté le 7ème jour.

Pour les tâches de streaming, si vous avez défini une fenêtre de maintenance, celle-ci sera redémarrée pendant la fenêtre de maintenance après 7 jours.

- `MaxCapacity` – Nombre (double).

Pour les tâches Glue version 1.0 ou antérieures, en utilisant le type de travailleur standard, le nombre d'unités de traitement des AWS Glue données (DPUs) pouvant être allouées lors de l'exécution de cette tâche. Un DPU est une mesure relative de la puissance de traitement

composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

Pour les tâches des versions 2.0 et ultérieures de Glue, vous ne pouvez pas spécifier un `Maximum capacity`. Au lieu de cela, vous devez spécifier `Worker type` et `Number of workers`.

Ne définissez pas `MaxCapacity` si vous utilisez `WorkerType` et `NumberOfWorkers`.

La valeur pouvant être attribuée à `MaxCapacity` varie selon que vous exécutez une tâche shell Python, une tâche ETL Apache Spark ou une tâche ETL Apache Spark Streaming :

- Lorsque vous spécifiez une tâche shell Python (`JobCommand.Name="pythonshell"`), vous pouvez allouer 0,0625 ou 1 DPU. La valeur par défaut correspond à 0,0625 DPU.
- Lorsque vous spécifiez une tâche ETL Apache Spark (`JobCommand.Name="glueetl »`) ou une tâche ETL de streaming Apache Spark (`JobCommand.Name="gluestreaming »`), vous pouvez en allouer de 2 à 100. DPUs La valeur par défaut est 10 DPUs. Ce type de tâche ne peut pas avoir une allocation DPU fractionnée.
- `WorkerType` – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type de travail prédéfini qui est alloué lorsqu'une tâche est exécutée. Accepte une valeur de `G.1X`, `G.2X`, `G.4X`, `G.8X` ou `G.025X` pour les tâches Spark. Accepte la valeur `Z.2X` pour les tâches Ray.

- Pour le type de `G.1X` worker, chaque worker est mappé à 1 DPU (4 vCPUs, 16 Go de mémoire) avec un disque de 94 Go, et fournit 1 exécuter par worker. Nous recommandons ce type de travailleur pour les charges de travail telles que les transformations de données, les jointures et les requêtes, afin de proposer un moyen évolutif et rentable d'exécuter la plupart des tâches.
- Pour le type de `G.2X` travailleur, chaque utilisateur est mappé sur 2 DPU (8 VCPUs, 32 Go de mémoire) avec un disque de 138 Go et fournit un exécuter par travailleur. Nous recommandons ce type de travailleur pour les charges de travail telles que les transformations de données, les jointures et les requêtes, afin de proposer un moyen évolutif et rentable d'exécuter la plupart des tâches.
- Pour le type de `G.4X` worker, chaque worker est mappé sur 4 DPU (16 vCPUs, 64 Go de mémoire) avec un disque de 256 Go, et fournit 1 exécuter par worker. Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes. Ce type de travailleur n'est disponible que pour les tâches Spark ETL AWS Glue version 3.0 ou ultérieure dans les AWS régions suivantes : USA Est (Ohio), USA Est (Virginie du Nord), USA Ouest (Oregon), Asie-

Pacifique (Singapour), Asie-Pacifique (Sydney), Asie-Pacifique (Tokyo), Canada (Centre), Europe (Francfort), Europe (Irlande) et Europe (Stockholm).

- Pour le type de G.8X travailleur, chaque travailleur est mappé sur 8 DPU (32 vCPUs, 128 Go de mémoire) avec un disque de 512 Go et fournit un exécuteur par travailleur. Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes. Ce type de travailleur n'est disponible que pour les tâches Spark ETL de AWS Glue version 3.0 ou ultérieure, dans les mêmes AWS régions que celles prises en charge pour le type de G.4X travailleur.
- Pour le type de G.025X worker, chaque worker est mappé sur 0,25 DPU (2 vCPUs, 4 Go de mémoire) avec un disque de 84 Go, et fournit 1 exécuteur par worker. Nous recommandons ce type d'employé pour les travaux de streaming à faible volume. Ce type de travailleur n'est disponible que pour les tâches de streaming en AWS Glue version 3.0 ou ultérieure.
- Pour le type de Z.2X travailleur, chaque utilisateur est mappé sur 2 M-DPU (8 VCPUs, 64 Go de mémoire) avec un disque de 128 Go et fournit jusqu'à 8 processeurs de rayons sur la base de l'autoscaler.
- `NumberOfWorkers` – Nombre (entier).

Nombre de travaux d'un `workerType` défini qui sont attribués lorsqu'une tâche est exécutée.

- `SecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la structure `SecurityConfiguration` à utiliser avec cette exécution de tâche.

- `LogGroupName` – Chaîne UTF-8.

Le nom du groupe de journaux pour la journalisation sécurisée qui peut être chiffré côté serveur sur Amazon CloudWatch à l'aide de AWS KMS. Ce nom peut avoir pour valeur `/aws-glue/jobs/`, auquel cas le chiffrement par défaut est NONE. Si vous ajoutez un nom de rôle et un nom `SecurityConfiguration` (en d'autres termes, `/aws-glue/jobs-yourRoleName-yourSecurityConfigurationName/`), cette configuration de sécurité est utilisée pour chiffrer le groupe de journaux.

- `NotificationProperty` – Un objet [NotificationProperty](#).

Spécifie les propriétés de configuration d'une notification d'exécution de tâche.

- `GlueVersion` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

Dans les tâches Spark, `GlueVersion` détermine les versions d'Apache Spark et de Python AWS Glue disponibles dans une tâche. La version de Python indique la version prise en charge pour les tâches de type Spark.

Les tâches Ray doivent définir `GlueVersion` sur 4.0 ou supérieur. Toutefois, les versions de Ray, de Python et des bibliothèques supplémentaires disponibles dans votre tâche Ray sont déterminées par le paramètre `Runtime` de la commande de tâche.

Pour plus d'informations sur les AWS Glue versions disponibles et les versions correspondantes de Spark et Python, consultez [la version de Glue](#) dans le guide du développeur.

Les tâches créées sans que la version de Glue soit spécifiée sont des tâches Glue 0.9 par défaut.

- `DPUSeconds` – Nombre (double).

Ce champ peut être défini pour les exécutions de tâches avec classe d'exécution FLEX ou lorsque Auto Scaling est activé. Il représente la durée totale d'exécution de chaque exécuteur pendant le cycle de vie d'une tâche en secondes, multipliée par un facteur DPU (1 pour G.1X, 2 pour G.2X ou 0,25 pour les G.025X travailleurs). Cette valeur peut être différente de la valeur `executionEngineRuntime * MaxCapacity` comme dans le cas des tâches Auto Scaling, car le nombre d'exécuteurs exécutés à un moment donné peut être inférieur à la `MaxCapacity`. Par conséquent, il est possible que la valeur de `DPUSeconds` soit inférieure à `executionEngineRuntime * MaxCapacity`.

- `ExecutionClass` – Chaîne UTF-8, d'une longueur maximale de 16 octets (valeurs valides : `FLEX=""` | `STANDARD=""`).

Indique si la tâche est exécutée avec une classe d'exécution standard ou flexible. La classe d'exécution standard est idéale pour les charges de travail urgentes qui nécessitent un démarrage rapide des tâches et des ressources dédiées.

La classe d'exécution flexible, adaptée aux tâches non urgentes dont les heures de début et de fin peuvent varier.

Seules les tâches dotées de AWS Glue la version 3.0 ou supérieure et du type de commande `glueetl` seront autorisées à être définies `ExecutionClass` sur FLEX. La classe d'exécution flexible est disponible pour les tâches Spark.

- `MaintenanceWindow` – Chaîne UTF-8, correspondant au [Custom string pattern #34](#).

Ce champ indique un jour de la semaine et une heure pour une fenêtre de maintenance pour les tâches de streaming. AWS Glue effectue périodiquement des activités de maintenance. Au cours de ces fenêtres de maintenance, vous AWS Glue devrez redémarrer vos tâches de streaming.

AWS Glue redémarrera le travail dans les 3 heures suivant la période de maintenance spécifiée. Par exemple, si vous configurez la fenêtre de maintenance pour le lundi à 10 h 00 GMT, vos tâches seront redémarrées entre 10 h 00 GMT et 13 h 00 GMT.

- **ProfileName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom d'un profil AWS Glue d'utilisation associé à la tâche exécutée.

- **StateDetail** – Chaîne UTF-8, d'une longueur maximale de 400 000 octets.

Ce champ contient des informations relatives à l'état d'une tâche exécutée. Le champ est nul.

Par exemple, lorsqu'une tâche est exécutée dans un état WAITING à la suite d'une mise en file d'attente, le champ indique la raison pour laquelle la tâche exécutée est dans cet état.

Structure de Predecessor

Exécution de tâche utilisée dans le prédicat d'un déclencheur conditionnel ayant déclenché cette exécution de tâche.

Champs

- **JobName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de tâche utilisée par la tâche exécutée précédente.

- **RunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution de tâche de l'exécution de tâche précédente.

JobBookmarkEntry structure

Définit un point à partir duquel une tâche peut reprendre le traitement.

Champs

- **JobName** – Chaîne UTF-8.

Nom de la tâche en question.

- **Version** – Nombre (entier).

Version de la tâche.

- **Run** – Nombre (entier).

Numéro d'identification de l'exécution.

- **Attempt** – Nombre (entier).

Numéro d'identification de la tentative.

- **PreviousRunId** – Chaîne UTF-8.

Identifiant d'exécution unique associé à l'exécution de tâche précédente.

- **RunId** – Chaîne UTF-8.

Numéro d'identification de l'exécution.

- **JobBookmark** – Chaîne UTF-8.

Le marque-page lui-même.

BatchStopJobRunSuccessfulSubmission structure

Enregistre une requête réussie visant à arrêter une JobRun spécifiée.

Champs

- **JobName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de tâche utilisée par la tâche exécutée qui a été arrêtée.

- **JobRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

JobRunId de la tâche qui a été arrêtée.

BatchStopJobRunError structure

Enregistre une erreur qui s'est produite lors de la tentative d'arrêt d'une tâche exécutée spécifiée.

Champs

- **JobName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de tâche utilisée par la tâche exécutée en question.

- **JobRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

JobRunId de l'exécution de tâche en question.

- **ErrorDetail** – Un objet [ErrorDetail](#).

Spécifie les détails de l'erreur qui s'est produite.

NotificationProperty structure

Spécifie les propriétés de configuration d'une notification.

Champs

- **NotifyDelayAfter** – Nombre (entier), au moins égal à 1.

Après le démarrage d'une exécution de tâche, nombre de minutes d'attente avant l'envoi d'une notification de délai d'exécution de tâche.

Opérations

- [StartJobRun action \(Python : start_job_run\)](#)
- [BatchStopJobRun action \(Python : batch_stop_job_run\)](#)
- [GetJobRun action \(Python : get_job_run\)](#)
- [GetJobRuns action \(Python : get_job_runs\)](#)
- [GetJobBookmark action \(Python : get_job_bookmark\)](#)
- [GetJobBookmarks action \(Python : get_job_bookmarks\)](#)
- [ResetJobBookmark action \(Python : reset_job_bookmark\)](#)

StartJobRun action (Python : start_job_run)

Démarre une exécution de tâche à l'aide d'une définition de tâche.

Demande

- **JobName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de tâche à utiliser.

- **JobRunQueuingEnabled** – Booléen.

Spécifie si la mise en file d'attente des tâches est activée pour l'exécution de la tâche.

La valeur true signifie que la mise en file d'attente des tâches est activée pour l'exécution de la tâche. Si la valeur est fausse ou si elle n'est pas renseignée, la tâche exécutée ne sera pas prise en compte pour la mise en file d'attente.

- **JobRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'une précédente JobRun pour une nouvelle tentative.

- **Arguments** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Arguments de la tâche associés à cette exécution. Pour cette exécution de tâche, ils remplacent les arguments par défaut définis pour la tâche elle-même.

Vous pouvez spécifier ici les arguments que votre propre script d'exécution de tâches consomme, ainsi que les arguments qu'il consomme AWS Glue lui-même.

Les arguments de la tâche peuvent être consignés. Ne transmettez pas de secrets en texte clair comme arguments. Récupérez les secrets d'une AWS Glue connexion AWS Secrets Manager ou d'un autre mécanisme de gestion des secrets si vous avez l'intention de les conserver dans le cadre du Job.

Pour plus d'informations sur la façon de spécifier et d'utiliser vos propres arguments Job, consultez la rubrique [Calling AWS Glue APIs in Python](#) du guide du développeur.

Pour plus d'informations sur les arguments que vous pouvez fournir dans ce champ lors de la configuration des tâches Spark, consultez la rubrique [Special Parameters Used by AWS Glue](#) dans le guide du développeur.

Pour plus d'informations sur les arguments que vous pouvez fournir dans ce champ lors de la configuration des tâches Ray, consultez [Utilisation des paramètres de tâches dans les tâches Ray](#) dans le guide du développeur.

- `AllocatedCapacity` – Nombre (entier).

Ce champ est obsolète. Utilisez `MaxCapacity` à la place.

Le nombre d'unités de traitement de AWS Glue données (DPU) à y affecter JobRun. Vous pouvez en allouer au moins 2 DPUs ; la valeur par défaut est 10. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

- `Timeout` – Nombre (entier), au moins égal à 1.

Délai d'expiration de JobRun en minutes. Durée maximale durant laquelle une tâche exécutée peut consommer des ressources avant qu'elle ne se termine et n'entre dans l'état `TIMEOUT`. Cette valeur remplace la valeur définie dans la tâche parent.

Les délais d'expiration des tâches doivent être inférieurs à 7 jours ou 10080 minutes. Dans le cas contraire, les tâches généreront une exception.

Lorsque la valeur est laissée vide, le délai d'expiration est défini par défaut à 2880 minutes.

Toutes les AWS Glue tâches existantes dont le délai d'expiration est supérieur à 7 jours seront définies par défaut sur 7 jours. Par exemple, si vous avez spécifié un délai d'expiration de 20 jours pour un traitement par lots, celui-ci sera arrêté le 7ème jour.

Pour les tâches de streaming, si vous avez défini une fenêtre de maintenance, celle-ci sera redémarrée pendant la fenêtre de maintenance après 7 jours.

- `MaxCapacity` – Nombre (double).

Pour les tâches Glue version 1.0 ou antérieures, en utilisant le type de travailleur standard, le nombre d'unités de traitement des AWS Glue données (DPUs) pouvant être allouées lors de l'exécution de cette tâche. Un DPU est une mesure relative de la puissance de traitement

composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

Pour les tâches des versions 2.0 et ultérieures de Glue, vous ne pouvez pas spécifier un `Maximum capacity`. Au lieu de cela, vous devez spécifier `Worker type` et `Number of workers`.

Ne définissez pas `MaxCapacity` si vous utilisez `WorkerType` et `NumberOfWorkers`.

La valeur pouvant être attribuée à `MaxCapacity` varie selon que vous exécutez une tâche shell Python, une tâche ETL Apache Spark ou une tâche ETL Apache Spark Streaming :

- Lorsque vous spécifiez une tâche shell Python (`JobCommand.Name="pythonshell"`), vous pouvez allouer 0,0625 ou 1 DPU. La valeur par défaut correspond à 0,0625 DPU.
- Lorsque vous spécifiez une tâche ETL Apache Spark (`JobCommand.Name="glueetl »`) ou une tâche ETL de streaming Apache Spark (`JobCommand.Name="gluestreaming »`), vous pouvez en allouer de 2 à 100. DPUs La valeur par défaut est 10 DPUs. Ce type de tâche ne peut pas avoir une allocation DPU fractionnée.
- `SecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la structure `SecurityConfiguration` à utiliser avec cette exécution de tâche.

- `NotificationProperty` – Un objet [NotificationProperty](#).

Spécifie les propriétés de configuration d'une notification d'exécution de tâche.

- `WorkerType` – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type de travail prédéfini qui est alloué lorsqu'une tâche est exécutée. Accepte une valeur de `G.1X`, `G.2X`, `G.4X`, `G.8X` ou `G.025X` pour les tâches Spark. Accepte la valeur `Z.2X` pour les tâches Ray.

- Pour le type de `G.1X` worker, chaque worker est mappé à 1 DPU (4 vCPUs, 16 Go de mémoire) avec un disque de 94 Go, et fournit 1 exécuteur par worker. Nous recommandons ce type de travailleur pour les charges de travail telles que les transformations de données, les jointures et les requêtes, afin de proposer un moyen évolutif et rentable d'exécuter la plupart des tâches.
- Pour le type de `G.2X` travailleur, chaque utilisateur est mappé sur 2 DPU (8 VCPUs, 32 Go de mémoire) avec un disque de 138 Go et fournit un exécuteur par travailleur. Nous recommandons ce type de travailleur pour les charges de travail telles que les transformations de données, les jointures et les requêtes, afin de proposer un moyen évolutif et rentable d'exécuter la plupart des tâches.

- Pour le type de G.4X worker, chaque worker est mappé sur 4 DPU (16 vCPUs, 64 Go de mémoire) avec un disque de 256 Go, et fournit 1 exécuteur par worker. Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes. Ce type de travailleur n'est disponible que pour les tâches Spark ETL AWS Glue version 3.0 ou ultérieure dans les AWS régions suivantes : USA Est (Ohio), USA Est (Virginie du Nord), USA Ouest (Oregon), Asie-Pacifique (Singapour), Asie-Pacifique (Sydney), Asie-Pacifique (Tokyo), Canada (Centre), Europe (Francfort), Europe (Irlande) et Europe (Stockholm).
- Pour le type de G.8X travailleur, chaque travailleur est mappé sur 8 DPU (32 vCPUs, 128 Go de mémoire) avec un disque de 512 Go et fournit un exécuteur par travailleur. Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes. Ce type de travailleur n'est disponible que pour les tâches Spark ETL de AWS Glue version 3.0 ou ultérieure, dans les mêmes AWS régions que celles prises en charge pour le type de G.4X travailleur.
- Pour le type de G.025X worker, chaque worker est mappé sur 0,25 DPU (2 vCPUs, 4 Go de mémoire) avec un disque de 84 Go, et fournit 1 exécuteur par worker. Nous recommandons ce type d'employé pour les travaux de streaming à faible volume. Ce type de travailleur n'est disponible que pour les tâches de streaming en AWS Glue version 3.0 ou ultérieure.
- Pour le type de Z.2X travailleur, chaque utilisateur est mappé sur 2 M-DPU (8 VCPUs, 64 Go de mémoire) avec un disque de 128 Go et fournit jusqu'à 8 processeurs de rayons sur la base de l'autoscaler.
- `NumberOfWorkers` – Nombre (entier).

Nombre de travaux d'un `workerType` défini qui sont attribués lorsqu'une tâche est exécutée.

- `ExecutionClass` – Chaîne UTF-8, d'une longueur maximale de 16 octets (valeurs valides : `FLEX=""` | `STANDARD=""`).

Indique si la tâche est exécutée avec une classe d'exécution standard ou flexible. La classe d'exécution standard est idéale pour les charges de travail urgentes qui nécessitent un démarrage rapide des tâches et des ressources dédiées.

La classe d'exécution flexible, adaptée aux tâches non urgentes dont les heures de début et de fin peuvent varier.

Seules les tâches dotées de AWS Glue la version 3.0 ou supérieure et du type de commande `glueetl` seront autorisées à être définies `ExecutionClass` sur `FLEX`. La classe d'exécution flexible est disponible pour les tâches Spark.

- **ProfileName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom d'un profil AWS Glue d'utilisation associé à la tâche exécutée.

Réponse

- **JobRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID attribuée à cette exécution de tâche.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentRunsExceededException`

BatchStopJobRun action (Python : `batch_stop_job_run`)

Arrête une ou plusieurs exécutions de tâche pour une définition de tâche spécifiée.

Demande

- **JobName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de tâche pour laquelle arrêter les exécutions de tâche.

- **JobRunIds** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 25 chaînes maximum.

Liste des JobRunIds qui doivent être arrêtés pour cette définition de tâche.

Réponse

- `SuccessfulSubmissions` – Un tableau d'objets [BatchStopJobRunSuccessfulSubmission](#).

Une liste de ceux JobRuns qui ont été soumis avec succès pour arrêt.

- `Errors` – Un tableau [BatchStopJobRunError](#) d'objets.

Liste des erreurs qui se sont produites lors de la tentative d'arrêt de JobRuns, incluant la `JobRunId` pour laquelle chaque erreur s'est produite et les détails de l'erreur.

Erreurs

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

GetJobRun action (Python : `get_job_run`)

Récupère les métadonnées d'une exécution de tâche donnée. L'historique d'exécution des tâches est accessible pendant 365 jours pour votre flux de travail et l'exécution des tâches.

Demande

- `JobName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de tâche en cours d'exécution.

- `RunId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de l'exécution de tâche.

- `PredecessorsIncluded` – Booléen.

True si une liste d'exécutions précédentes doit être renvoyée.

Réponse

- `JobRun` – Un objet [JobRun](#).

Métadonnées de l'exécution de tâche demandée.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

GetJobRuns action (Python : `get_job_runs`)

Récupère les métadonnées de toutes les exécutions d'une définition de tâche donnée.

`GetJobRuns` renvoie les tâches exécutées par ordre chronologique, les tâches les plus récentes étant renvoyées en premier.

Demande

- `JobName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la définition de tâche pour laquelle récupérer toutes les exécutions de tâche.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

- `MaxResults`— Nombre (entier), pas moins de 1 ou plus de 200.

Taille maximale de la réponse.

Réponse

- `JobRuns` – Un tableau d'objets [JobRun](#).

Liste des objets de métadonnées de l'exécution de tâche.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, si toutes les exécutions de tâche demandées ne sont pas renvoyées.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

GetJobBookmark action (Python : `get_job_bookmark`)

Renvoie des informations sur une entrée de marque-page de tâche.

Pour plus d'informations sur l'activation et l'utilisation des marque-pages de tâche, consultez :

- [Suivi des données traitées à l'aide de signets de tâche](#)
- [Paramètres du Job utilisés par AWS Glue](#)
- [Structure de tâche](#)

Demande

- `JobName` – Obligatoire : chaîne UTF-8.

Nom de la tâche en question.

- `Version` – Nombre (entier).

Version de la tâche.

- `RunId` – Chaîne UTF-8.

Identifiant d'exécution unique associé à l'exécution de cette tâche.

Réponse

- `JobBookmarkEntry` – Un objet [JobBookmarkEntry](#).

Structure qui définit un point à partir duquel une tâche peut reprendre le traitement.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ValidationException`

GetJobBookmarks action (Python : `get_job_bookmarks`)

Renvoie des informations sur les données de marque-page de tâche. La liste est classée par numéros de version décroissants.

Pour plus d'informations sur l'activation et l'utilisation des marque-pages de tâche, consultez :

- [Suivi des données traitées à l'aide de signets de tâche](#)
- [Paramètres du Job utilisés par AWS Glue](#)
- [Structure de tâche](#)

Demande

- `JobName` – Obligatoire : chaîne UTF-8.

Nom de la tâche en question.

- `MaxResults` – Nombre (entier).

Taille maximale de la réponse.

- `NextToken` – Nombre (entier).

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- `JobBookmarkEntries` – Un tableau [JobBookmarkEntry](#) d'objets.

Liste de données de marque-page de tâche qui définit un point à partir duquel une tâche peut reprendre son exécution.

- NextToken – Nombre (entier).

Jeton de continuation, qui prend la valeur 1 si toutes les entrées sont renvoyées, ou > 1 si toutes les exécutions de tâches demandées n'ont pas été renvoyées.

Erreurs

- InvalidInputException
- EntityNotFoundException
- InternalServiceException
- OperationTimeoutException

ResetJobBookmark action (Python : reset_job_bookmark)

Réinitialise une donnée de marque-page.

Pour plus d'informations sur l'activation et l'utilisation des marque-pages de tâche, consultez :

- [Suivi des données traitées à l'aide de signets de tâche](#)
- [Paramètres du Job utilisés par AWS Glue](#)
- [Structure de tâche](#)

Demande

- JobName – Obligatoire : chaîne UTF-8.

Nom de la tâche en question.

- RunId – Chaîne UTF-8.

Identifiant d'exécution unique associé à l'exécution de cette tâche.

Réponse

- JobBookmarkEntry – Un objet [JobBookmarkEntry](#).

Donnée de marque-page de réinitialisation.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Déclencheurs

L'API Triggers décrit les types de données et l'API liés à la création, à la mise à jour ou à la suppression, ainsi qu'au démarrage et à l'arrêt des déclencheurs de tâches dans AWS Glue.

Types de données

- [Structure Trigger](#)
- [TriggerUpdate structure](#)
- [Structure Predicate](#)
- [Structure Condition](#)
- [Structure Action](#)
- [EventBatchingCondition structure](#)

Structure Trigger

Informations concernant un déclencheur spécifique.

Champs

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom du déclencheur.

- **WorkflowName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail associé au déclencheur.

- **Id** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Réservé pour un usage futur.

- Type – Chaîne UTF-8 (valeurs valides : SCHEDULED | CONDITIONAL | ON_DEMAND | EVENT).

Type de déclencheur.

- State – Chaîne UTF-8 (valeurs valides : CREATING | CREATED | ACTIVATING | ACTIVATED | DEACTIVATING | DEACTIVATED | DELETING | UPDATING).

État actuel du déclencheur.

- Description – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de ce déclencheur.

- Schedule – Chaîne UTF-8.

Une expression cron utilisée pour spécifier la planification (consultez [Time-Based Schedules for Jobs and Crawlers](#) (Planifications temporelles pour les tâches et les crawlers)). Par exemple, pour exécuter un élément tous les jours à 12h15 UTC, vous devez spécifier : cron(15 12 * * ? *).

- Actions – Un tableau [Action](#) d'objets.

Actions initiées par ce déclencheur.

- Predicate – Un objet [Prédicat](#).

Prédicat de ce déclencheur, qui définit le moment du déclenchement.

- EventBatchingCondition – Un objet [EventBatchingCondition](#).

Condition de lot qui doit être remplie (nombre spécifié d'événements reçus ou délai de traitement du lot expiré) avant que EventBridge l'événement ne se déclenche.

TriggerUpdate structure

Structure utilisée pour fournir des informations utilisées pour mettre à jour un déclencheur. Cet objet met à jour la définition précédente du déclencheur en la remplaçant complètement.

Champs

- Name – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Réservé pour un usage futur.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de ce déclencheur.

- **Schedule** – Chaîne UTF-8.

Une expression cron utilisée pour spécifier la planification (consultez [Time-Based Schedules for Jobs and Crawlers](#) (Planifications temporelles pour les tâches et les crawlers)). Par exemple, pour exécuter un élément tous les jours à 12h15 UTC, vous devez spécifier : `cron(15 12 * * ? *)`.

- **Actions** – Un tableau [Action](#) d'objets.

Actions initiées par ce déclencheur.

- **Predicate** – Un objet [Prédicat](#).

Prédicat de ce déclencheur, qui définit le moment du déclenchement.

- **EventBatchingCondition** – Un objet [EventBatchingCondition](#).

Condition de lot qui doit être remplie (nombre spécifié d'événements reçus ou délai de traitement du lot expiré) avant que EventBridge l'événement ne se déclenche.

Structure Predicate

Définit le prédicat du déclencheur, qui détermine le moment du déclenchement.

Champs

- **Logical** – Chaîne UTF-8 (valeurs valides : AND | ANY).

Champ facultatif si une seule condition est répertoriée. Si plusieurs conditions sont répertoriées, ce champ est obligatoire.

- **Conditions**— Un ensemble d'[Condition](#)objets, pas plus de 500 structures.

Liste des conditions qui déterminent le moment du déclenchement.

Structure Condition

Définit une condition selon laquelle un déclencheur s'exécute.

Champs

- `LogicalOperator` – Chaîne UTF-8 (valeurs valides : EQUALS).

Opérateur logique.

- `JobName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la tâche pour laquelle cette condition s'applique à JobRuns et sur laquelle ce déclencheur attend.

- `State`— Chaîne UTF-8 (valeurs valides : STARTING | RUNNING | STOPPING | STOPPED | SUCCEEDED | FAILED | TIMEOUT ERROR WAITING | EXPIRED).

État de la condition. Actuellement, les seuls états de tâche qu'un déclencheur peut écouter sont SUCCEEDED, STOPPED, FAILED et TIMEOUT. Les seuls états d'crawler qu'un déclencheur peut écouter sont SUCCEEDED, FAILED et CANCELLED.

- `CrawlerName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'crawler à laquelle cette condition s'applique.

- `CrawlState` – Chaîne UTF-8 (valeurs valides : RUNNING | CANCELLING | CANCELLED | SUCCEEDED | FAILED | ERROR).

Nom de l'crawler à laquelle cette condition s'applique.

Structure Action

Définit une action qui doit être initiée par un déclencheur.

Champs

- `JobName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la tâche à exécuter.

- `Arguments` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Arguments de tâche utilisés lorsque ce déclencheur s'exécute. Pour cette exécution de tâche, ils remplacent les arguments par défaut définis pour la tâche elle-même.

Vous pouvez spécifier ici les arguments que votre propre script d'exécution de tâches consomme, ainsi que les arguments qu'il consomme AWS Glue lui-même.

Pour plus d'informations sur la façon de spécifier et d'utiliser vos propres arguments Job, consultez la rubrique [Calling AWS Glue APIs in Python](#) du guide du développeur.

Pour plus d'informations sur les paires clé-valeur nécessaires AWS Glue à la configuration de votre tâche, consultez la AWS Glue rubrique [Paramètres spéciaux utilisés par](#) dans le guide du développeur.

- **Timeout** – Nombre (entier), au moins égal à 1.

Délai d'expiration de JobRun en minutes. Durée maximale durant laquelle une tâche exécutée peut consommer des ressources avant qu'elle ne se termine et n'entre dans l'état TIMEOUT. Cette valeur remplace la valeur définie dans la tâche parent.

Les délais d'expiration des tâches doivent être inférieurs à 7 jours ou 10080 minutes. Dans le cas contraire, les tâches généreront une exception.

Lorsque la valeur est laissée vide, le délai d'expiration est défini par défaut à 2880 minutes.

Toutes les AWS Glue tâches existantes dont le délai d'expiration est supérieur à 7 jours seront définies par défaut sur 7 jours. Par exemple, si vous avez spécifié un délai d'expiration de 20 jours pour un traitement par lots, celui-ci sera arrêté le 7ème jour.

Pour les tâches de streaming, si vous avez défini une fenêtre de maintenance, celle-ci sera redémarrée pendant la fenêtre de maintenance après 7 jours.

- **SecurityConfiguration** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la structure SecurityConfiguration à utiliser avec cette action.

- **NotificationProperty** – Un objet [NotificationProperty](#).

Spécifie les propriétés de configuration d'une notification d'exécution de tâche.

- **CrawlerName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'crawler à utiliser avec cette action.

EventBatchingCondition structure

Condition de lot qui doit être remplie (nombre spécifié d'événements reçus ou délai de traitement du lot expiré) avant que EventBridge l'événement ne se déclenche.

Champs

- **BatchSize** – obligatoire : nombre (entier), compris entre 1 et 100.

Nombre d'événements qui doivent être reçus d'Amazon EventBridge avant que l' EventBridge événement ne déclenche un incendie.

- **BatchWindow** – nombre (entier), compris entre 1 et 900.

Fenêtre de temps en secondes après laquelle EventBridge l'événement déclenche des incendies. La fenêtre démarre dès la réception du premier événement.

Opérations

- [CreateTrigger action \(Python : create_trigger\)](#)
- [StartTrigger action \(Python : start_trigger\)](#)
- [GetTrigger action \(Python : get_trigger\)](#)
- [GetTriggers action \(Python : get_triggers\)](#)
- [UpdateTrigger action \(Python : update_trigger\)](#)
- [StopTrigger action \(Python : stop_trigger\)](#)
- [DeleteTrigger action \(Python : delete_trigger\)](#)
- [ListTriggers action \(Python : list_triggers\)](#)
- [BatchGetTriggers action \(Python : batch_get_triggers\)](#)

CreateTrigger action (Python : create_trigger)

Crée un nouveau déclencheur.

Les arguments de la tâche peuvent être consignés. Ne transmettez pas de secrets en texte clair comme arguments. Récupérez les secrets d'une AWS Glue connexion, d'un Gestionnaire de AWS Secrets ou d'un autre mécanisme de gestion des secrets si vous avez l'intention de les conserver dans le cadre du Job.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom du déclencheur.

- **WorkflowName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail associé au déclencheur.

- **Type** – obligatoire : chaîne UTF-8 (valeurs valides : SCHEDULED | CONDITIONAL | ON_DEMAND | EVENT).

Type du nouveau déclencheur.

- **Schedule** – Chaîne UTF-8.

Une expression cron utilisée pour spécifier la planification (consultez [Time-Based Schedules for Jobs and Crawlers](#) (Planifications temporelles pour les tâches et les crawlers)). Par exemple, pour exécuter un élément tous les jours à 12h15 UTC, vous devez spécifier : `cron(15 12 * * ? *)`.

Ce champ est obligatoire lorsque le type de déclencheur est SCHEDULED.

- **Predicate** – Un objet [Prédicat](#).

Prédicat pour spécifier le moment du déclenchement.

Ce champ est obligatoire lorsque le type de déclencheur est CONDITIONAL.

- **Actions** – Obligatoire : Un tableau d'objets [Action](#).

Actions initiées par ce déclencheur lorsqu'il s'exécute.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du nouveau déclencheur.

- **StartOnCreation** – Booléen.

Définissez ce paramètre sur `true` pour démarrer les déclencheurs `SCHEDULED` et `CONDITIONAL` lorsqu'ils sont créés. `True` n'est pas pris en charge pour les déclencheurs `ON_DEMAND`.

- `Tags` – tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Balises à utiliser avec ce déclencheur. Vous pouvez utiliser des balises pour limiter l'accès au déclencheur. Pour plus d'informations sur les tags in AWS Glue, voir [AWS Tags in AWS Glue](#) dans le guide du développeur.

- `EventBatchingCondition` – Un objet [EventBatchingCondition](#).

Condition de lot qui doit être remplie (nombre spécifié d'événements reçus ou délai de traitement du lot expiré) avant que EventBridge l'événement ne se déclenche.

Réponse

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom du déclencheur.

Erreurs

- `AlreadyExistsException`
- `EntityNotFoundException`
- `InvalidInputException`
- `IdempotentParameterMismatchException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`

StartTrigger action (Python : start_trigger)

Lance un déclencheur existant. Consultez [Déclenchement de tâches](#) pour obtenir des informations sur la manière dont différents types de déclencheurs sont lancés.

Demande

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du déclencheur à lancer.

Réponse

- Name – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du déclencheur qui a été lancé.

Erreurs

- InvalidInputException
- InternalServiceException
- EntityNotFoundException
- OperationTimeoutException
- ResourceNumberLimitExceededException
- ConcurrentRunsExceededException

GetTrigger action (Python : get_trigger)

Extrait la définition d'un déclencheur.

Demande

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du déclencheur à extraire.

Réponse

- **Trigger** – Un objet [Déclencheur](#).

Définition du déclencheur demandé.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

GetTriggers action (Python : `get_triggers`)

Permet d'obtenir tous les déclencheurs associés à une tâche.

Demande

- **NextToken** – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

- **DependentJobName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la tâche pour laquelle récupérer des déclencheurs. Le déclencheur qui peut lancer cette tâche est renvoyé. Si aucun déclencheur de ce type n'existe, tous les déclencheurs sont renvoyés.

- **MaxResults**— Nombre (entier), pas moins de 1 ou plus de 200.

Taille maximale de la réponse.

Réponse

- **Triggers** – Un tableau d'objets [Déclencheur](#).

Liste des déclencheurs pour la tâche spécifiée.

- **NextToken** – Chaîne UTF-8.

Jeton de continuation, si tous les déclencheurs demandés ne sont pas encore renvoyés.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

UpdateTrigger action (Python : `update_trigger`)

Met à jour la définition d'un déclencheur.

Les arguments de la tâche peuvent être consignés. Ne transmettez pas de secrets en texte clair comme arguments. Récupérez les secrets d'une AWS Glue connexion, d'un Gestionnaire de AWS Secrets ou d'un autre mécanisme de gestion des secrets si vous avez l'intention de les conserver dans le cadre du Job.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du déclencheur à mettre à jour.

- **TriggerUpdate** – Obligatoire : un objet [TriggerUpdate](#).

Nouvelles valeurs pour mettre à jour le déclencheur.

Réponse

- **Trigger** – Un objet [Déclencheur](#).

Définition du déclencheur obtenu.

Erreurs

- `InvalidInputException`

- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

StopTrigger action (Python : `stop_trigger`)

Arrête un déclencheur spécifié.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du déclencheur à arrêter.

Réponse

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du déclencheur qui a été arrêté.

Erreurs

- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

DeleteTrigger action (Python : `delete_trigger`)

Supprime un déclencheur spécifié. Si le déclencheur est introuvable, aucune exception n'est levée.

Demande

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du déclencheur à supprimer.

Réponse

- Name – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du déclencheur qui a été supprimé.

Erreurs

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

ListTriggers action (Python : `list_triggers`)

Récupère les noms de toutes les ressources de déclenchement de ce AWS compte ou des ressources portant le tag spécifié. Cette opération vous permet de voir quelles ressources sont disponibles dans votre compte, et leurs noms.

Cette opération accepte le champ Tags facultatif que vous pouvez utiliser comme filtre sur la réponse, afin que les ressources balisées puissent être récupérées en tant que groupe. Si vous choisissez d'utiliser le filtrage des balises, seules les ressources avec la balise sont récupérées.

Demande

- NextToken – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'une requête de continuation.

- DependentJobName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la tâche pour laquelle récupérer les déclencheurs. Le déclencheur qui peut lancer cette tâche est renvoyé. Si aucun déclencheur de ce type n'existe, tous les déclencheurs sont renvoyés.

- `MaxResults`— Nombre (entier), pas moins de 1 ou plus de 200.

La taille maximale d'une liste à renvoyer.

- `Tags` – tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Spécifie de renvoyer uniquement les ressources balisées.

Réponse

- `TriggerNames` – Tableau de chaînes UTF-8.

Noms de tous les déclencheurs dans le compte ou des déclencheurs avec les balises spécifiées.

- `NextToken` – Chaîne UTF-8.

Jeton continuation, si la liste renvoyée ne contient pas la dernière métrique disponible.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

BatchGetTriggers action (Python : `batch_get_triggers`)

Renvoie la liste des métadonnées de ressource pour une liste donnée de noms de déclencheur. Après avoir appelé l'opération `ListTriggers`, vous pouvez appeler cette opération pour accéder aux données sur lesquelles des autorisations vous ont été octroyées. Cette opération prend en charge toutes les autorisations IAM, y compris les conditions d'autorisation qui utilisent des balises.

Demande

- `TriggerNames` – obligatoire : tableau de chaînes UTF-8.

Liste des noms de déclencheur, qui peuvent être les noms renvoyés à partir de l'opération `ListTriggers`.

Réponse

- `Triggers` – Un tableau d'objets [Déclencheur](#).

Liste des définitions de déclencheur.

- `TriggersNotFound` – Tableau de chaînes UTF-8.

Liste des noms des déclencheurs introuvables.

Erreurs

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Intégration APIs dans AWS Glue

Types de données

- [Structure d'intégration](#)
- [IntegrationConfig structure](#)
- [IntegrationPartition structure](#)
- [IntegrationError structure](#)
- [IntegrationFilter structure](#)
- [InboundIntegration structure](#)
- [SourceProcessingProperties structure](#)
- [TargetProcessingProperties structure](#)
- [SourceTableConfig structure](#)

- [TargetTableConfig structure](#)

Structure d'intégration

Décrit une intégration zéro ETL.

Champs

- **SourceArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de la source de l'intégration.

- **TargetArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de la cible de l'intégration.

- **Description**— Chaîne UTF-8, d'une longueur maximale de 1 000 octets, correspondant au. [Custom string pattern #12](#)

Description de l'intégration.

- **IntegrationName**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Nom unique pour l'intégration.

- **IntegrationArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Le nom de ressource Amazon (ARN) pour l'intégration.

- **KmsKeyId**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

L'ARN d'une clé KMS utilisée pour chiffrer le canal.

- **AdditionalEncryptionContext** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Ensemble facultatif de paires clé-valeur non secrètes contenant des informations contextuelles supplémentaires pour le chiffrement. Cela ne peut être fourni que s'il KMSKeyId est fourni.

- **Tags** – Un tableau d'objets [Tag](#).

Les métadonnées attribuées à la ressource consistent en une liste de paires clé-valeur.

- **Status – Obligatoire** : Chaîne UTF-8 (valeurs valides : CREATING | ACTIVE | MODIFYING | FAILED | DELETING | SYNCING | NEEDS_ATTENTION).

Les statuts possibles sont les suivants :

- **CRÉATION** : L'intégration est en cours de création.
- **ACTIF** : La création de l'intégration réussit.
- **MODIFICATION** : L'intégration est en cours de modification.
- **ÉCHEC** : La création de l'intégration échoue.
- **SUPPRESSION** : L'intégration est supprimée.
- **SYNCHRONISATION** : L'intégration est en cours de synchronisation.
- **ATTENTION REQUISE** : L'intégration nécessite une attention particulière, telle que la synchronisation.
- **CreateTime – obligatoire** : horodatage.

Heure à laquelle l'intégration a été créée, en UTC.

- **IntegrationConfig** – Un objet [IntegrationConfig](#).

Propriétés associées à l'intégration.

- **Errors** – Un tableau d'objets [IntegrationError](#).

Liste des erreurs associées à l'intégration.

- **DataFilter**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Sélectionne les tables sources pour l'intégration à l'aide de la syntaxe du filtre Maxwell.

IntegrationConfig structure

Propriétés associées à l'intégration.

Champs

- **RefreshInterval** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Spécifie la fréquence à laquelle le CDC (Change Data Capture) doit effectuer des extractions ou des charges incrémentielles. Ce paramètre offre la flexibilité nécessaire pour aligner le taux de

rafraîchissement sur vos modèles de mise à jour des données spécifiques, les considérations relatives à la charge du système et les objectifs d'optimisation des performances. L'incrément de temps peut être réglé de 15 minutes à 8 640 minutes (six jours). Supporte actuellement `RefreshInterval` uniquement la création de.

- `SourceProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Collection de paires clé-valeur qui spécifient des propriétés supplémentaires pour la source d'intégration. Ces propriétés fournissent des options de configuration qui peuvent être utilisées pour personnaliser le comportement de la source ODB lors des opérations d'intégration de données.

IntegrationPartition structure

Structure qui décrit la manière dont les données sont partitionnées sur la cible.

Champs

- `FieldName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Nom du champ utilisé pour partitionner les données sur la cible. Évitez d'utiliser des colonnes qui ont des valeurs uniques pour chaque ligne (par exemple, `LastModifiedTimestamp` « », `SystemModTimeStamp` « ») comme colonne de partition. Ces colonnes ne sont pas adaptées au partitionnement car elles créent un grand nombre de petites partitions, ce qui peut entraîner des problèmes de performances.

- `FunctionSpec` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Spécifie la fonction utilisée pour partitionner les données sur la cible. La seule valeur acceptée pour ce paramètre est « identity » (chaîne). La fonction « identité » garantit que le partitionnement des données sur la cible suit le même schéma que celui de la source. En d'autres termes, la structure de partitionnement des données sources est préservée dans la destination cible.

- `ConversionSpec` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Spécifie le format d'horodatage des données sources. Les valeurs valides sont :

- `epoch_sec`- Horodatage de l'époque Unix en secondes

- `epoch_milli`- Horodatage de l'époque Unix en millisecondes
- `iso`- Horodatage au format ISO 8601

Note

Spécifiez uniquement `ConversionSpec` lorsque vous utilisez des fonctions de partition basées sur l'horodatage (année, mois, jour ou heure). AWS Glue Zero-ETL utilise ce paramètre pour transformer correctement les données source au format d'horodatage avant le partitionnement.

N'utilisez pas de colonnes à cardinalité élevée avec la fonction de `identity` partition. Les colonnes à haute cardinalité incluent :

- Clés primaires
- Champs d'horodatage (tels `LastModifiedTimestamp` que,) `CreatedDate`
- Horodatages générés par le système

L'utilisation de colonnes à haute cardinalité avec partitionnement des identités crée de nombreuses petites partitions, ce qui peut considérablement dégrader les performances d'ingestion.

IntegrationError structure

Erreur associée à une intégration zéro ETL.

Champs

- `ErrorCode` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Code associé à cette erreur.

- `ErrorMessage`— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Message décrivant l'erreur.

IntegrationFilter structure

Filtre qui peut être utilisé lors de l'appel d'une `DescribeIntegrations` demande.

Champs

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Nom du filtre.

- **Values** – Tableau de chaînes UTF-8.

Une liste de valeurs de filtre.

InboundIntegration structure

Structure pour une intégration qui écrit des données dans une ressource.

Champs

- **SourceArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de la ressource source pour l'intégration.

- **TargetArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de la ressource cible pour l'intégration.

- **IntegrationArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de l'intégration Zero-ETL.

- **Status** – Obligatoire : Chaîne UTF-8 (valeurs valides : `CREATING` | `ACTIVE` | `MODIFYING` | `FAILED` | `DELETING` | `SYNCING` | `NEEDS_ATTENTION`).

Les statuts possibles sont les suivants :

- **CRÉATION** : L'intégration est en cours de création.
- **ACTIF** : La création de l'intégration réussit.
- **MODIFICATION** : L'intégration est en cours de modification.
- **ÉCHEC** : La création de l'intégration échoue.
- **SUPPRESSION** : L'intégration est supprimée.
- **SYNCHRONISATION** : L'intégration est en cours de synchronisation.
- **ATTENTION REQUISE** : L'intégration nécessite une attention particulière, telle que la synchronisation.

- **CreateTime** – obligatoire : horodatage.

Heure à laquelle l'intégration a été créée, en UTC.

- **IntegrationConfig** – Un objet [IntegrationConfig](#).

Propriétés associées à l'intégration.

- **Errors** – Un tableau d'objets [IntegrationError](#).

Liste des erreurs associées à l'intégration.

SourceProcessingProperties structure

Les propriétés des ressources associées à la source d'intégration.

Champs

- **RoleArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Rôle IAM permettant d'accéder à la AWS Glue connexion.

TargetProcessingProperties structure

Les propriétés des ressources associées à la cible d'intégration.

Champs

- **RoleArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Rôle IAM permettant d'accéder à la AWS Glue base de données.

- **KmsArn**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

L'ARN de la clé KMS utilisée pour le chiffrement.

- **ConnectionName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Connexion AWS Glue réseau permettant de configurer la AWS Glue tâche exécutée dans le VPC du client.

- **EventBusArn**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

L'ARN d'un bus d'événements Eventbridge pour recevoir la notification d'état de l'intégration.

SourceTableConfig structure

Propriétés utilisées par l'étape source pour traiter les données de la source.

Champs

- `Fields` – Tableau de chaînes UTF-8.

Liste des champs utilisés pour le filtrage au niveau des colonnes. Non prise en charge actuellement.

- `FilterPredicate` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Clause de condition utilisée pour le filtrage au niveau des lignes. Non prise en charge actuellement.

- `PrimaryKey` – Tableau de chaînes UTF-8.

Fournissez le jeu de clés primaires pour cette table. Actuellement pris en charge spécifiquement pour `EntityOf` les entités SAP sur demande. Contactez AWS le Support pour rendre cette fonctionnalité disponible.

- `RecordUpdateField` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Champ d'extraction incrémentiel basé sur l'horodatage. Non prise en charge actuellement.

TargetTableConfig structure

Propriétés utilisées par le segment cible pour partitionner les données sur la cible.

Champs

- `UnnestSpec` – Chaîne UTF-8 (valeurs valides : `TOPLEVEL` | `FULL` | `NOUNNEST`).

Spécifie la manière dont les objets imbriqués sont aplatis par rapport aux éléments de niveau supérieur. Les valeurs valides sont : « `TOPLEVEL` », « `FULL` » ou « `NOUNNEST` ».

- `PartitionSpec` – Un tableau d'objets [IntegrationPartition](#).

Détermine la mise en page du fichier sur la cible.

- `TargetTableName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Nom facultatif d'une table cible.

Opérations

- [CreateIntegration action \(Python : create_integration\)](#)
- [ModifyIntegration action \(Python : modifier_intégration\)](#)
- [DescribeIntegrations action \(Python : describe_integrations\)](#)
- [DeleteIntegration action \(Python : delete_integration\)](#)
- [DescribeInboundIntegrations action \(Python : describe_inbound_integrations\)](#)
- [CreateIntegrationTableProperties action \(Python : create_integration_table_properties\)](#)
- [UpdateIntegrationTableProperties action \(Python : update_integration_table_properties\)](#)
- [GetIntegrationTableProperties action \(Python : get_integration_table_properties\)](#)
- [DeleteIntegrationTableProperties action \(Python : delete_integration_table_properties\)](#)
- [CreateIntegrationResourceProperty action \(Python : create_integration_resource_property\)](#)
- [UpdateIntegrationResourceProperty action \(Python : update_integration_resource_property\)](#)
- [GetIntegrationResourceProperty action \(Python : get_integration_resource_property\)](#)
- [UntagResource action \(Python : untag_resource\)](#)
- [ListTagsForResource action \(Python : list_tags_for_resource\)](#)

CreateIntegration action (Python : create_integration)

Crée une intégration zéro ETL dans le compte de l'appelant entre deux ressources portant Amazon Resource Names (ARNs) : le `SourceArn` et `TargetArn`

Demande

- **IntegrationName**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Nom unique pour une intégration dans AWS Glue.

- **SourceArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de la ressource source pour l'intégration.

- **TargetArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de la ressource cible pour l'intégration.

- **Description**— Chaîne UTF-8, d'une longueur maximale de 1 000 octets, correspondant au. [Custom string pattern #12](#)

Description de l'intégration.

- **DataFilter**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Sélectionne les tables sources pour l'intégration à l'aide de la syntaxe du filtre Maxwell.

- **KmsKeyId**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

L'ARN d'une clé KMS utilisée pour chiffrer le canal.

- **AdditionalEncryptionContext** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Ensemble facultatif de paires clé-valeur non secrètes contenant des informations contextuelles supplémentaires pour le chiffrement. Cela ne peut être fourni que s'il KmsKeyId est fourni.

- **Tags** – Un tableau d'objets [Tag](#).

Les métadonnées attribuées à la ressource consistent en une liste de paires clé-valeur.

- **IntegrationConfig** – Un objet [IntegrationConfig](#).

Paramètres de configuration.

Réponse

- **SourceArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de la ressource source pour l'intégration.

- **TargetArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de la ressource cible pour l'intégration.

- **IntegrationName**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Nom unique pour une intégration dans AWS Glue.

- **Description**— Chaîne UTF-8, d'une longueur maximale de 1 000 octets, correspondant au. [Custom string pattern #12](#)

Description de l'intégration.

- **IntegrationArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Le nom de ressource Amazon (ARN) pour l'intégration créée.

- **KmsKeyId**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

L'ARN d'une clé KMS utilisée pour chiffrer le canal.

- **AdditionalEncryptionContext** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Ensemble facultatif de paires clé-valeur non secrètes contenant des informations contextuelles supplémentaires pour le chiffrement.

- **Tags** – Un tableau d'objets [Tag](#).

Les métadonnées attribuées à la ressource consistent en une liste de paires clé-valeur.

- **Status** – Obligatoire : Chaîne UTF-8 (valeurs valides : CREATING | ACTIVE | MODIFYING | FAILED | DELETING | SYNCING | NEEDS_ATTENTION).

État de l'intégration en cours de création.

Les statuts possibles sont les suivants :

- **CRÉATION** : L'intégration est en cours de création.
- **ACTIF** : La création de l'intégration réussit.
- **MODIFICATION** : L'intégration est en cours de modification.
- **ÉCHEC** : La création de l'intégration échoue.
- **SUPPRESSION** : L'intégration est supprimée.
- **SYNCHRONISATION** : L'intégration est en cours de synchronisation.
- **ATTENTION REQUISE** : L'intégration nécessite une attention particulière, telle que la synchronisation.
- **CreateTime** – obligatoire : horodatage.

Heure à laquelle l'intégration a été créée, en UTC.

- **Errors** – Un tableau d'objets [IntegrationError](#).

Liste des erreurs associées à la création de l'intégration.

- **DataFilter**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Sélectionne les tables sources pour l'intégration à l'aide de la syntaxe du filtre Maxwell.

- **IntegrationConfig** – Un objet [IntegrationConfig](#).

Paramètres de configuration.

Erreurs

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerErrorException`
- `IntegrationConflictOperationFault`
- `IntegrationQuotaExceededFault`
- `KMSKeyNotAccessibleFault`
- `EntityNotFoundException`
- `InternalServiceException`
- `ConflictException`
- `ResourceNumberLimitExceededException`
- `InvalidInputException`

ModifyIntegration action (Python : `modifier_intégration`)

Modifie une intégration zéro ETL dans le compte de l'appelant.

Demande

- **IntegrationIdentifier**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Le nom de ressource Amazon (ARN) pour l'intégration.

- **Description**— Chaîne UTF-8, d'une longueur maximale de 1 000 octets, correspondant au. [Custom string pattern #12](#)

Description de l'intégration.

- **DataFilter**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Sélectionne les tables sources pour l'intégration à l'aide de la syntaxe du filtre Maxwell.

- **IntegrationName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Nom unique pour une intégration dans AWS Glue.

Réponse

- **SourceArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de la source pour l'intégration.

- **TargetArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de la cible pour l'intégration.

- **IntegrationName**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Nom unique pour une intégration dans AWS Glue.

- **Description**— Chaîne UTF-8, d'une longueur maximale de 1 000 octets, correspondant au. [Custom string pattern #12](#)

Description de l'intégration.

- **IntegrationArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Le nom de ressource Amazon (ARN) pour l'intégration.

- **KmsKeyId**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

L'ARN d'une clé KMS utilisée pour chiffrer le canal.

- **AdditionalEncryptionContext** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Ensemble facultatif de paires clé-valeur non secrètes contenant des informations contextuelles supplémentaires pour le chiffrement.

- Tags – Un tableau d'objets [Tag](#).

Les métadonnées attribuées à la ressource consistent en une liste de paires clé-valeur.

- Status – Obligatoire : Chaîne UTF-8 (valeurs valides : CREATING | ACTIVE | MODIFYING | FAILED | DELETING | SYNCING | NEEDS_ATTENTION).

État de l'intégration en cours de modification.

Les statuts possibles sont les suivants :

- CRÉATION : L'intégration est en cours de création.
- ACTIF : La création de l'intégration réussit.
- MODIFICATION : L'intégration est en cours de modification.
- ÉCHEC : La création de l'intégration échoue.
- SUPPRESSION : L'intégration est supprimée.
- SYNCHRONISATION : L'intégration est en cours de synchronisation.
- ATTENTION REQUISE : L'intégration nécessite une attention particulière, telle que la synchronisation.
- CreateTime – obligatoire : horodatage.

Heure à laquelle l'intégration a été créée, en UTC.

- Errors – Un tableau d'objets [IntegrationError](#).

Liste des erreurs associées à la modification de l'intégration.

- DataFilter— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Sélectionne les tables sources pour l'intégration à l'aide de la syntaxe du filtre Maxwell.

Erreurs

- ValidationException

- `AccessDeniedException`
- `InternalServerException`
- `IntegrationNotFoundFault`
- `IntegrationConflictOperationFault`
- `InvalidIntegrationStateFault`
- `EntityNotFoundExceptio`
- `InternalServiceException`
- `ConflictException`
- `InvalidStateException`
- `InvalidInputException`

DescribeIntegrations action (Python : `describe_integrations`)

L'API est utilisée pour récupérer une liste d'intégrations.

Demande

- `IntegrationIdentifier` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Le nom de ressource Amazon (ARN) pour l'intégration.

- `Marker` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Valeur qui indique le point de départ de la prochaine série d'enregistrements de réponses dans une demande ultérieure.

- `MaxRecords` – Nombre (entier).

Le nombre total d'éléments à renvoyer dans la sortie.

- `Filters` – Un tableau d'objets [IntegrationFilter](#).

Une liste de clés et de valeurs, pour filtrer les résultats. Les touches prises en charge sont « `Status` », `IntegrationName` « » et « `SourceArn` ». `IntegrationName` est limité à une seule valeur.

Réponse

- `Integrations` – Un tableau d'objets [Integration](#).

Liste des intégrations sans ETL.

- **Marker** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Valeur qui indique le point de départ de la prochaine série d'enregistrements de réponses dans une demande ultérieure.

Erreurs

- `ValidationException`
- `AccessDeniedException`
- `InternalServerErrorException`
- `IntegrationNotFoundFault`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

DeleteIntegration action (Python : `delete_integration`)

Supprime l'intégration zéro ETL spécifiée.

Demande

- **IntegrationIdentifier**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Le nom de ressource Amazon (ARN) pour l'intégration.

Réponse

- **SourceArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de la source pour l'intégration.

- **TargetArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de la cible pour l'intégration.

- **IntegrationName**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Nom unique pour une intégration dans AWS Glue.

- **Description**— Chaîne UTF-8, d'une longueur maximale de 1 000 octets, correspondant au. [Custom string pattern #12](#)

Description de l'intégration.

- **IntegrationArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Le nom de ressource Amazon (ARN) pour l'intégration.

- **KmsKeyId**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

L'ARN d'une clé KMS utilisée pour chiffrer le canal.

- **AdditionalEncryptionContext** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Ensemble facultatif de paires clé-valeur non secrètes contenant des informations contextuelles supplémentaires pour le chiffrement.

- **Tags** – Un tableau d'objets [Tag](#).

Les métadonnées attribuées à la ressource consistent en une liste de paires clé-valeur.

- **Status** – Obligatoire : Chaîne UTF-8 (valeurs valides : CREATING | ACTIVE | MODIFYING | FAILED | DELETING | SYNCING | NEEDS_ATTENTION).

État de l'intégration en cours de suppression.

Les statuts possibles sont les suivants :

- **CRÉATION** : L'intégration est en cours de création.
- **ACTIF** : La création de l'intégration réussit.
- **MODIFICATION** : L'intégration est en cours de modification.
- **ÉCHEC** : La création de l'intégration échoue.

- **SUPPRESSION** : L'intégration est supprimée.

- **SYNCHRONISATION** : L'intégration est en cours de synchronisation.
- **ATTENTION REQUISE** : L'intégration nécessite une attention particulière, telle que la synchronisation.
- **CreateTime** – obligatoire : horodatage.

Heure à laquelle l'intégration a été créée, en UTC.

- **Errors** – Un tableau d'objets [IntegrationError](#).

Liste des erreurs associées à l'intégration.

- **DataFilter**— Chaîne UTF-8 d'une longueur d'au moins 1 ou supérieure à 2 048 octets.

Sélectionne les tables sources pour l'intégration à l'aide de la syntaxe du filtre Maxwell.

Erreurs

- `ValidationException`
- `AccessDeniedException`
- `InternalServerErrorException`
- `IntegrationNotFoundFault`
- `IntegrationConflictOperationFault`
- `InvalidIntegrationStateFault`
- `EntityNotFoundException`
- `InternalServiceException`
- `ConflictException`
- `InvalidStateException`
- `InvalidInputException`

DescribeInboundIntegrations action (Python : `describe_inbound_integrations`)

Renvoie la liste des intégrations entrantes pour l'intégration spécifiée.

Demande

- **IntegrationArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Le nom de ressource Amazon (ARN) de l'intégration.

- **Marker** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Jeton permettant de spécifier où commencer la pagination. Il s'agit du marqueur d'une réponse précédemment tronquée.

- **MaxRecords** – Nombre (entier).

Le nombre total d'éléments à renvoyer dans la sortie.

- **TargetArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Le nom de ressource Amazon (ARN) de la ressource cible dans l'intégration.

Réponse

- **InboundIntegrations** – Un tableau d'objets [InboundIntegration](#).

Liste des intégrations entrantes.

- **Marker** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Valeur qui indique le point de départ de la prochaine série d'enregistrements de réponses dans une demande ultérieure.

Erreurs

- **ValidationException**
- **AccessDeniedException**
- **InternalServerErrorException**
- **IntegrationNotFoundFault**
- **TargetResourceNotFound**
- **OperationNotSupportedException**
- **EntityNotFoundException**
- **InternalServiceException**
- **InvalidInputException**

CreateIntegrationTableProperties action (Python : create_integration_table_properties)

Cette API est utilisée pour fournir des propriétés de remplacement facultatives pour les tables qui doivent être répliquées. Ces propriétés peuvent inclure des propriétés de filtrage et de partitionnement pour les tables source et cible. Pour définir à la fois les propriétés source et cible, la même API doit être invoquée avec l'ARN de AWS Glue connexion comme `ResourceArn` avec `SourceTableConfig`, et l'ARN AWS Glue de base de données comme `ResourceArn` avec `TargetTableConfig` respectivement.

Demande

- `ResourceArn`— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Nom de ressource Amazon (ARN) de la table cible pour laquelle créer les propriétés de la table d'intégration. Actuellement, cette API prend uniquement en charge la création de propriétés de table d'intégration pour les tables cibles, et l'ARN fourni doit être l'ARN de la table cible dans le catalogue de AWS Glue données. Support pour la création de propriétés de table d'intégration pour les connexions source (à l'aide de l'ARN de connexion) n'est pas encore implémenté et sera ajouté dans une future version.

- `TableName`— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Nom de la table à répliquer.

- `SourceTableConfig` – Un objet [SourceTableConfig](#).

Structure pour la configuration de la table source. Consultez la `SourceTableConfig` structure pour voir la liste des propriétés source prises en charge.

- `TargetTableConfig` – Un objet [TargetTableConfig](#).

Structure pour la configuration de la table cible.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `ValidationException`

- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerErrorException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

UpdateIntegrationTableProperties action (Python : `update_integration_table_properties`)

Cette API est utilisée pour fournir des propriétés de remplacement facultatives pour les tables qui doivent être répliquées. Ces propriétés peuvent inclure des propriétés de filtrage et de partitionnement pour les tables source et cible. Pour définir à la fois les propriétés source et cible, la même API doit être invoquée avec l'ARN de AWS Glue connexion comme `ResourceArn` avec `SourceTableConfig`, et l'ARN AWS Glue de base de données comme `ResourceArn` avec `TargetTableConfig` respectivement.

La dérogation sera reflétée dans toutes les intégrations utilisant la même table `ResourceArn` et la table source.

Demande

- `ResourceArn`— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de connexion de la source ou l'ARN de base de données de la cible.

- `TableName`— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Nom de la table à répliquer.

- `SourceTableConfig` – Un objet [SourceTableConfig](#).

Structure pour la configuration de la table source.

- `TargetTableConfig` – Un objet [TargetTableConfig](#).

Structure pour la configuration de la table cible.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerErrorException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

GetIntegrationTableProperties action (Python : `get_integration_table_properties`)

Cette API est utilisée pour récupérer les propriétés de remplacement facultatives pour les tables qui doivent être répliquées. Ces propriétés peuvent inclure des propriétés de filtrage et de partition pour les tables source et cible.

Demande

- **ResourceArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Nom de ressource Amazon (ARN) de la table cible pour laquelle récupérer les propriétés de la table d'intégration. Actuellement, cette API prend uniquement en charge la récupération des propriétés des tables cibles, et l'ARN fourni doit être l'ARN de la table cible dans le catalogue de AWS Glue données. Support pour la récupération des propriétés des tables d'intégration pour les connexions source (à l'aide de l'ARN de connexion) n'est pas encore implémenté et sera ajouté dans une future version.

- **TableName**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Nom de la table à répliquer.

Réponse

- **ResourceArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Nom de ressource Amazon (ARN) de la table cible pour laquelle récupérer les propriétés de la table d'intégration. Actuellement, cette API prend uniquement en charge la récupération des propriétés des tables cibles, et l'ARN fourni doit être l'ARN de la table cible dans le catalogue de AWS Glue données. Support pour la récupération des propriétés des tables d'intégration pour les connexions source (à l'aide de l'ARN de connexion) n'est pas encore implémenté et sera ajouté dans une future version.

- **TableName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Nom de la table à répliquer.

- **SourceTableConfig** – Un objet [SourceTableConfig](#).

Structure pour la configuration de la table source.

- **TargetTableConfig** – Un objet [TargetTableConfig](#).

Structure pour la configuration de la table cible.

Erreurs

- **ValidationException**
- **AccessDeniedException**
- **ResourceNotFoundException**
- **InternalServerErrorException**
- **EntityNotFoundException**
- **InternalServiceException**
- **InvalidInputException**

DeleteIntegrationTableProperties action (Python : `delete_integration_table_properties`)

Supprime les propriétés de table créées pour les tables devant être répliquées.

Demande

- **ResourceArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de connexion de la source ou l'ARN de base de données de la cible.

- **TableName**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

Nom de la table à répliquer.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerErrorException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

CreateIntegrationResourceProperty action (Python : `create_integration_resource_property`)

Cette API peut être utilisée pour configurer la AWS Glue connexion (pour `ResourceProperty` la source) ou l'ARN de la AWS Glue base de données (pour la cible). Ces propriétés peuvent inclure le rôle permettant d'accéder à la connexion ou à la base de données. Pour définir à la fois les propriétés source et cible, la même API doit être invoquée avec l'ARN de AWS Glue connexion comme `ResourceArn` avec `SourceProcessingProperties` et l'ARN AWS Glue de base de données comme `ResourceArn` avec `TargetProcessingProperties` respectivement.

Demande

- **ResourceArn**— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de connexion de la source ou l'ARN de base de données de la cible.

- `SourceProcessingProperties` – Un objet [SourceProcessingProperties](#).

Les propriétés des ressources associées à la source d'intégration.

- `TargetProcessingProperties` – Un objet [TargetProcessingProperties](#).

Les propriétés des ressources associées à la cible d'intégration.

Réponse

- `ResourceArn`— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de connexion de la source ou l'ARN de base de données de la cible.

- `SourceProcessingProperties` – Un objet [SourceProcessingProperties](#).

Les propriétés des ressources associées à la source d'intégration.

- `TargetProcessingProperties` – Un objet [TargetProcessingProperties](#).

Les propriétés des ressources associées à la cible d'intégration.

Erreurs

- `ValidationException`
- `AccessDeniedException`
- `ConflictException`
- `InternalServerErrorException`
- `ResourceNotFoundException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

UpdateIntegrationResourceProperty action (Python : `update_integration_resource_property`)

Cette API peut être utilisée pour mettre à jour `ResourceProperty` la AWS Glue connexion (pour la source) ou l'ARN de la AWS Glue base de données (pour la cible). Ces propriétés peuvent inclure le rôle permettant d'accéder à la connexion ou à la base de données. Comme la même ressource peut être utilisée dans plusieurs intégrations, la mise à jour des propriétés des ressources aura un impact sur toutes les intégrations qui l'utilisent.

Demande

- `ResourceArn`— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.

L'ARN de connexion de la source ou l'ARN de base de données de la cible.

- `SourceProcessingProperties` – Un objet [SourceProcessingProperties](#).

Les propriétés des ressources associées à la source d'intégration.

- `TargetProcessingProperties` – Un objet [TargetProcessingProperties](#).

Les propriétés des ressources associées à la cible d'intégration.

Réponse

- `ResourceArn` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

L'ARN de connexion de la source ou l'ARN de base de données de la cible.

- `SourceProcessingProperties` – Un objet [SourceProcessingProperties](#).

Les propriétés des ressources associées à la source d'intégration.

- `TargetProcessingProperties` – Un objet [TargetProcessingProperties](#).

Les propriétés des ressources associées à la cible d'intégration.

Erreurs

- `ValidationException`
- `AccessDeniedException`
- `InternalServerErrorException`

- `ResourceNotFoundException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

GetIntegrationResourceProperty action (Python : `get_integration_resource_property`)

Cette API est utilisée pour récupérer la AWS Glue connexion (pour `ResourceProperty` la source) ou l'ARN de la AWS Glue base de données (pour la cible)

Demande

- `ResourceArn`— Obligatoire : chaîne UTF-8 d'une longueur d'au moins 1 ou de plus de 128 octets.
L'ARN de connexion de la source ou l'ARN de base de données de la cible.

Réponse

- `ResourceArn` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.
L'ARN de connexion de la source ou l'ARN de base de données de la cible.
- `SourceProcessingProperties` – Un objet [SourceProcessingProperties](#).
Les propriétés des ressources associées à la source d'intégration.
- `TargetProcessingProperties` – Un objet [TargetProcessingProperties](#).
Les propriétés des ressources associées à la cible d'intégration.

Erreurs

- `ValidationException`
- `AccessDeniedException`
- `InternalServerErrorException`
- `ResourceNotFoundException`
- `EntityNotFoundException`

- `InternalServiceException`
- `InvalidInputException`

UntagResource action (Python : `untag_resource`)

Supprime les balises spécifiées d'une ressource d'intégration.

Demande

- `ResourceArn` – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

Le nom de ressource Amazon (ARN) de la ressource d'intégration.

- `TagsToRemove` – Obligatoire : Tableau de chaînes UTF-8, avec 50 chaînes maximum.

Liste des balises de métadonnées à supprimer de la ressource.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `ResourceNotFoundException`

ListTagsForResource action (Python : `list_tags_for_resource`)

Répertorie les balises de métadonnées attribuées à la ressource spécifiée.

Demande

- `ResourceARN` – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'ARN de la ressource.

Réponse

- Tags – Un tableau d'objets [Tag](#), 10 structures au maximum.

Une liste de balises.

Erreurs

- `ResourceNotFoundException`

Exceptions

- [ResourceNotFoundException structure](#)
- [InternalServerError structure](#)
- [IntegrationAlreadyExistsFault structure](#)
- [IntegrationConflictOperationFault structure](#)
- [IntegrationQuotaExceededFault structure](#)
- [KMSKeyNotAccessibleFault structure](#)
- [IntegrationNotFoundFault structure](#)
- [TargetResourceNotFound structure](#)
- [InvalidIntegrationStateFault structure](#)

ResourceNotFoundException structure

La ressource n'a pas pu être trouvée.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

InternalServerError structure

Une erreur interne du serveur s'est produite.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

IntegrationAlreadyExistsFault structure

L'intégration spécifiée existe déjà.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

IntegrationConflictOperationFault structure

L'opération demandée est en conflit avec une autre opération.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

IntegrationQuotaExceededFault structure

Les données traitées dans le cadre de votre intégration ont dépassé votre quota.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

KMSKeyNotAccessibleFault structure

La clé KMS spécifiée n'est pas accessible.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

IntegrationNotFoundFault structure

L'intégration spécifiée n'a pas pu être trouvée.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

TargetResourceNotFound structure

La ressource cible n'a pas pu être trouvée.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

InvalidIntegrationStateFault structure

L'état de l'intégration n'est pas valide.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

Séances interactives API

L'API des sessions interactives décrit l' AWS Glue API liée à l'utilisation de sessions AWS Glue interactives pour créer et tester des scripts d'extraction, de transformation et de chargement (ETL) pour l'intégration de données.

Types de données

- [Structure de séance](#)
- [SessionCommand structure](#)
- [Structure de la déclaration](#)
- [StatementOutput structure](#)
- [StatementOutputData structure](#)
- [ConnectionsList structure](#)

Structure de séance

Période pendant laquelle un environnement d'exécution Spark distant est en cours d'exécution.

Champs

- **Id** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de la séance.

- **CreatedOn** – Horodatage.

Date et heure de création de la séance.

- **Status** – Chaîne UTF-8 (valeurs valides : PROVISIONING | READY | FAILED | TIMEOUT | STOPPING | STOPPED).

Statut d'une séance.

- **ErrorMessage** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Le message d'erreur affiché pendant la séance.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la séance.

- **Role** – chaîne UTF-8, d'une longueur comprise entre 20 et 2048 octets, correspondant au [Custom string pattern #30](#).

Nom ou Amazon Resource Name (ARN) du rôle IAM associé à la séance.

- **Command** – Un objet [SessionCommand](#).

L'objet de commande. Voir. [SessionCommand](#)

- **DefaultArguments** – Tableau de mappage de paires valeur-clé, avec 75 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Chaque valeur est une chaîne UTF-8, d'une longueur ne dépassant pas 4096 octets, correspondant au [URI address multi-line string pattern](#).

Tableau de mappage de paires valeur-clé. Le maximum est de 75 paires.

- **Connections** – Un objet [ConnectionsList](#).

Nombre de connexions utilisées pour la séance.

- **Progress** – Nombre (double).

La progression de l'exécution du code de la séance.

- **MaxCapacity** – Nombre (double).

Le nombre d'unités de traitement de AWS Glue données (DPUs) qui peuvent être allouées lors de l'exécution de la tâche. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire.

- **SecurityConfiguration** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la SecurityConfiguration structure à utiliser avec la session.

- **GlueVersion** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

La AWS Glue version détermine les versions d'Apache Spark et de Python prises en charge. Le GlueVersion doit être supérieur à 2,0.

- `DataAccessId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 36 octets.

ID d'accès aux données de la séance.

- `PartitionId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 36 octets.

L'ID de partition de la séance.

- `NumberOfWorkers` – Nombre (entier).

Nombre d'utilisateurs d'une `WorkerType` définie pour la séance.

- `WorkerType` – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type de travail prédéfini qui est alloué lorsqu'une session est exécutée. Accepte une valeur de `G.1X`, `G.2X`, `G.4X` ou `G.8X` pour les sessions Spark. Accepte la valeur `Z.2X` pour les sessions Ray.

- `CompletedOn` – Horodatage.

La date et heure à laquelle cette session s'est terminée.

- `ExecutionTime` – Nombre (double).

La durée totale de la session.

- `DPUSeconds` – Nombre (double).

La DPU consommation par la séance (formule : $\text{ExecutionTime} * \text{MaxCapacity}$).

- `IdleTimeout` – Nombre (entier).

Le nombre de minutes d'inactivité avant l'expiration de la session.

- `ProfileName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom d'un profil AWS Glue d'utilisation associé à la session.

SessionCommand structure

La commande `SessionCommand` qui exécute cette tâche.

Champs

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Spécifie le nom du SessionCommand. Il peut s'agir de « gluetel » ou de « gluestreaming ».

- **PythonVersion** – Chaîne UTF-8, correspondant au [Custom string pattern #48](#).

Spécifie la version de Python utilisée. La version de Python indique la version prise en charge pour les tâches de type Spark.

Structure de la déclaration

La déclaration ou la demande pour qu'une action particulière se produise dans une séance.

Champs

- **Id** – Nombre (entier).

ID de la déclaration.

- **Code** – Chaîne UTF-8.

Code d'exécution de la déclaration.

- **State** – Chaîne UTF-8 (valeurs valides: WAITING | RUNNING | AVAILABLE | CANCELLING | CANCELLED | |).

État pendant que la demande est exécutée.

- **Output** – Un objet [StatementOutput](#).

Le résultat en JSON.

- **Progress** – Nombre (double).

La progression de l'exécution du code.

- **StartedOn** – Nombre (long).

Date et heure Unix de démarrage de la définition de tâche.

- **CompletedOn** – Nombre (long).

Date et heure Unix auxquelles la définition de tâche a été terminée.

StatementOutput structure

Résultat de l'exécution de code au format JSON.

Champs

- Data – Un objet [StatementOutputData](#).

Résultat de l'exécution de code.

- ExecutionCount – Nombre (entier).

Nombre d'exécution du résultat.

- Status – Chaîne UTF-8 (valeurs valides : WAITING | RUNNING | AVAILABLE | CANCELLING | CANCELLED | ERROR).

Statut du résultat de l'exécution de code.

- ErrorName – Chaîne UTF-8.

Nom de l'erreur dans le résultat.

- ErrorValue – Chaîne UTF-8.

Valeur de l'erreur du résultat.

- Traceback – Tableau de chaînes UTF-8.

Le retraçage du résultat.

StatementOutputData structure

Résultat de l'exécution de code au format JSON.

Champs

- TextPlain – Chaîne UTF-8.

Résultat de l'exécution de code au format texte.

ConnectionsList structure

Spécifie les connexions utilisées par une tâche.

Champs

- **Connections**— Un tableau de chaînes UTF-8 ne dépassant pas 1 000 chaînes.

Liste de connexions utilisées par la tâche.

Opérations

- [CreateSession action \(Python : créer_session\)](#)
- [StopSession action \(Python : stop_session\)](#)
- [DeleteSession action \(Python : supprimer_session\)](#)
- [GetSession action \(Python : get_session\)](#)
- [ListSessions action \(Python : list_sessions\)](#)
- [RunStatement action \(Python : run_statement\)](#)
- [CancelStatement action \(Python : annuler_statement\)](#)
- [GetStatement action \(Python : get_statement\)](#)
- [ListStatements action \(Python : list_statements\)](#)

CreateSession action (Python : créer_session)

Crée une nouvelle séance.

Demande

Demande de création d'une nouvelle séance.

- **Id** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de la séance demandée

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la séance.

- **Role** – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 20 et 2048 octets, correspondant au [Custom string pattern #30](#).

Un ARN de rôle IAM

- **Command** – Obligatoire : un objet [SessionCommand](#).

La commande `SessionCommand` qui exécute cette tâche.

- **Timeout** – Nombre (entier), au moins égal à 1.

Nombre de minutes avant l'expiration de la séance. La valeur par défaut pour les tâches Spark ETL est de 48 heures (2880 minutes). Consultez la documentation pour les autres types de tâches.

- **IdleTimeout** – Nombre (entier), au moins égal à 1.

Nombre de minutes d'inactivité avant l'expiration de la séance. La valeur par défaut pour les tâches ETL Spark est la valeur du délai d'expiration. Consultez la documentation pour les autres types de tâches.

- **DefaultArguments** – Tableau de mappage de paires valeur-clé, avec 75 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Chaque valeur est une chaîne UTF-8, d'une longueur ne dépassant pas 4096 octets, correspondant au [URI address multi-line string pattern](#).

Tableau de mappage de paires valeur-clé. Le maximum est de 75 paires.

- **Connections** – Un objet [ConnectionsList](#).

Nombre de connexions à utiliser pour la séance.

- **MaxCapacity** – Nombre (double).

Le nombre d'unités de traitement de AWS Glue données (DPUs) qui peuvent être allouées lors de l'exécution de la tâche. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire.

- **NumberOfWorkers** – Nombre (entier).

Nombre d'utilisateurs d'une `WorkerType` définie pour la séance.

- **WorkerType** – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type de travail prédéfini qui est alloué lorsqu'une tâche est exécutée. Accepte une valeur de G.1X, G.2X, G.4X ou G.8X pour les tâches Spark. Accepte la valeur Z.2X pour les blocs-notes Ray.

- Pour le type de G.1X worker, chaque worker est mappé à 1 DPU (4 vCPUs, 16 Go de mémoire) avec un disque de 94 Go, et fournit 1 exécuteur par worker. Nous recommandons ce type de travailleur pour les charges de travail telles que les transformations de données, les jointures et les requêtes, afin de proposer un moyen évolutif et rentable d'exécuter la plupart des tâches.
- Pour le type de G.2X travailleur, chaque utilisateur est mappé sur 2 DPU (8 VCPUs, 32 Go de mémoire) avec un disque de 138 Go et fournit un exécuteur par travailleur. Nous recommandons ce type de travailleur pour les charges de travail telles que les transformations de données, les jointures et les requêtes, afin de proposer un moyen évolutif et rentable d'exécuter la plupart des tâches.
- Pour le type de G.4X worker, chaque worker est mappé sur 4 DPU (16 vCPUs, 64 Go de mémoire) avec un disque de 256 Go, et fournit 1 exécuteur par worker. Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes. Ce type de travailleur n'est disponible que pour les tâches Spark ETL AWS Glue version 3.0 ou ultérieure dans les AWS régions suivantes : USA Est (Ohio), USA Est (Virginie du Nord), USA Ouest (Oregon), Asie-Pacifique (Singapour), Asie-Pacifique (Sydney), Asie-Pacifique (Tokyo), Canada (Centre), Europe (Francfort), Europe (Irlande) et Europe (Stockholm).
- Pour le type de G.8X travailleur, chaque travailleur est mappé sur 8 DPU (32 vCPUs, 128 Go de mémoire) avec un disque de 512 Go et fournit un exécuteur par travailleur. Nous recommandons ce type de travailleur pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes. Ce type de travailleur n'est disponible que pour les tâches Spark ETL de AWS Glue version 3.0 ou ultérieure, dans les mêmes AWS régions que celles prises en charge pour le type de G.4X travailleur.
- Pour le type de Z.2X travailleur, chaque utilisateur est mappé sur 2 M-DPU (8 VCPUs, 64 Go de mémoire) avec un disque de 128 Go et fournit jusqu'à 8 processeurs de rayons sur la base de l'autoscaler.
- `SecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la `SecurityConfiguration` structure à utiliser avec la session

- `GlueVersion` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

La AWS Glue version détermine les versions d'Apache Spark et de Python prises AWS Glue en charge. Le GlueVersion doit être supérieur à 2,0.

- **DataAccessId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 36 octets.

ID d'accès aux données de la séance.

- **PartitionId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 36 octets.

ID de partition de la séance.

- **Tags** – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Carte des paires de valeurs clés (balises) appartenant à la séance.

- **RequestOrigin** – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Origine de la demande.

- **ProfileName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom d'un profil AWS Glue d'utilisation associé à la session.

Réponse

- **Session** – Un objet [Session](#).

Retourne l'objet de séance dans la réponse.

Erreurs

- **AccessDeniedException**
- **IdempotentParameterMismatchException**
- **InternalServiceException**
- **OperationTimeoutException**
- **InvalidInputException**

- ValidationException
- AlreadyExistsException
- ResourceNumberLimitExceededException

StopSession action (Python : stop_session)

Arrête la séance.

Demande

- Id – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de la séance à arrêter.

- RequestOrigin – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Origine de la demande.

Réponse

- Id – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Retourne l'ID de la séance arrêtée.

Erreurs

- AccessDeniedException
- InternalServiceException
- OperationTimeoutException
- InvalidInputException
- IllegalSessionStateException
- ConcurrentModificationException

DeleteSession action (Python : supprimer_session)

Supprime la séance.

Demande

- **Id** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de la séance à supprimer.

- **RequestOrigin** – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Nom de l'origine de la demande de suppression de séance.

Réponse

- **Id** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Renvoie l'ID de la séance supprimée.

Erreurs

- `AccessDeniedException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `IllegalSessionStateException`
- `ConcurrentModificationException`

GetSession action (Python : get_session)

Récupère la séance.

Demande

- **Id** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de la séance.

- **RequestOrigin** – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Origine de la demande.

Réponse

- **Session** – Un objet [Session](#).

L'objet récupéré est renvoyé dans la réponse.

Erreurs

- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

ListSessions action (Python : `list_sessions`)

Extrait une liste de séances.

Demande

- **NextToken** – Chaîne UTF-8, d'une longueur maximale de 400 000 octets.

Jeton pour l'ensemble de résultats suivant, ou null s'il n'y a pas de résultats supplémentaires.

- **MaxResults** – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats.

- **Tags** – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Balises appartenant à la séance.

- `RequestOrigin` – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Origine de la demande.

Réponse

- `Ids` – Tableau de chaînes UTF-8.

Retourne l'ID de la séance

- `Sessions` – Un tableau d'objets [Session](#).

Retourne l'objet de la séance.

- `NextToken` – Chaîne UTF-8, d'une longueur maximale de 400 000 octets.

Jeton pour l'ensemble de résultats suivant, ou null s'il n'y a pas de résultats supplémentaires.

Erreurs

- `AccessDeniedException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

RunStatement action (Python : `run_statement`)

Exécute la déclaration.

Demande

- `SessionId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de séance de la déclaration à exécuter.

- Code – Obligatoire : Chaîne UTF-8, d'une longueur ne dépassant pas 68000 octets.

Code de la déclaration à exécuter.

- RequestOrigin – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Origine de la demande.

Réponse

- Id – Nombre (entier).

Renvoie l'ID de la déclaration exécutée.

Erreurs

- EntityNotFoundException
- AccessDeniedException
- InternalServiceException
- OperationTimeoutException
- InvalidInputException
- ValidationException
- ResourceNumberLimitExceededException
- IllegalSessionStateException

CancelStatement action (Python : annuler_statement)

Annule la déclaration.

Demande

- SessionId – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de séance de la déclaration à annuler.

- **Id** – Obligatoire : nombre (entier).

ID de la déclaration à annuler.

- **RequestOrigin** – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Origine de la demande d'annuler la déclaration.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `IllegalSessionStateException`

GetStatement action (Python : `get_statement`)

Récupère la déclaration.

Demande

- **SessionId** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de séance de la déclaration.

- **Id** – Obligatoire : nombre (entier).

L'ID de la déclaration.

- **RequestOrigin** – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Origine de la demande.

Réponse

- Statement – Un objet [Instruction](#).

Renvoie la déclaration.

Erreurs

- AccessDeniedException
- EntityNotFoundException
- InternalServiceException
- OperationTimeoutException
- InvalidInputException
- IllegalSessionStateException

ListStatements action (Python : list_statements)

Répertorie les déclarations de la séance.

Demande

- SessionId – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de séance des déclarations.

- RequestOrigin – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Origine de la demande de liste des déclarations.

- NextToken – Chaîne UTF-8, d'une longueur maximale de 400 000 octets.

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- Statements – Un tableau d'objets [Instruction](#).

Renvoie la liste des déclarations.

- NextToken – Chaîne UTF-8, d'une longueur maximale de 400 000 octets.

Jeton de continuation, si toutes les déclarations n'ont pas encore été retournées.

Erreurs

- AccessDeniedException
- EntityNotFoundException
- InternalServiceException
- OperationTimeoutException
- InvalidInputException
- IllegalSessionStateException

API de points de terminaison de développement

L'API Development endpoints décrit l' AWS Glue API liée aux tests à l'aide d'une personnalisation DevEndpoint.

Types de données

- [DevEndpoint structure](#)
- [DevEndpointCustomLibraries structure](#)

DevEndpoint structure

Point de terminaison de développement où un développeur peut déboguer à distance des scripts ETL (extraction, transformation et chargement).

Champs

- EndpointName – Chaîne UTF-8.

Le nom de l'DevEndpoint.

- `RoleArn` – Chaîne UTF-8, correspondant au [AWS IAM ARN string pattern](#).

Amazon Resource Name (ARN) du rôle IAM utilisé dans ce DevEndpoint.

- `SecurityGroupIds` – Tableau de chaînes UTF-8.

Liste d'identifiants de groupe de sécurité utilisés dans ce DevEndpoint.

- `SubnetId` – Chaîne UTF-8.

ID de sous-réseau pour ce DevEndpoint.

- `YarnEndpointAddress` – Chaîne UTF-8.

Adresse du point de terminaison YARN utilisée par ce DevEndpoint.

- `PrivateAddress` – Chaîne UTF-8.

Adresse IP privée pour accéder au DevEndpoint au sein d'un VPC si le DevEndpoint est créé dans celui-ci. Le champ `PrivateAddress` est présent uniquement lorsque vous créez le DevEndpoint au sein de votre VPC.

- `ZeppelinRemoteSparkInterpreterPort` – Nombre (entier).

Port Apache Zeppelin pour l'interpréteur Apache Spark à distance.

- `PublicAddress` – Chaîne UTF-8.

Adresse IP publique utilisée par ce DevEndpoint. Le champ `PublicAddress` est présent uniquement lorsque vous créez un DevEndpoint de cloud privé non virtuel.

- `Status` – Chaîne UTF-8.

Statut actuel de ce DevEndpoint.

- `WorkerType` – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type de travail prédéfini qui est alloué au point de terminaison de développement. Accepte la valeur `Standard`, `G.1X` ou `G.2X`.

- Pour le type de travail `Standard`, chaque travail fournit 4 vCPU, 16 Go de mémoire et 50 Go de disque, ainsi que 2 exécuteurs par travail.

- Pour le type de travail `G.1X`, chaque travail mappe vers 1 DPU (4 vCPU, 16 Go de mémoire et 64 Go de disque), et fournit 1 exécuteur par travail. Nous vous recommandons ce type d'employé pour les tâches utilisant beaucoup de mémoire.
- Pour le type de travail `G.2X`, chaque travail mappe vers 2 DPU (8 vCPU, 32 Go de mémoire et 128 Go de disque), et fournit 1 exécuteur par travail. Nous vous recommandons ce type d'employé pour les tâches utilisant beaucoup de mémoire.

Problème connu : lorsqu'un point de terminaison de développement est créé avec la configuration `G.2X WorkerType`, les pilotes Spark pour le point de terminaison de développement s'exécutent sur 4 vCPU, 16 Go de mémoire et un disque de 64 Go.

- `GlueVersion` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

La version de Glue détermine les versions d'Apache Spark et Python prises AWS Glue en charge. La version de Python indique la version prise en charge pour l'exécution de vos scripts ETL sur les points de terminaison de développement.

Pour plus d'informations sur les AWS Glue versions disponibles et les versions correspondantes de Spark et Python, consultez [la version de Glue](#) dans le guide du développeur.

Les points de terminaison de développement créés sans spécifier une version de Glue utilisent par défaut Glue 0.9.

Vous pouvez spécifier une version du support Python pour les points de terminaison de développement en utilisant le `Arguments` paramètre dans le `CreateDevEndpoint` ou `UpdateDevEndpoint` APIs. Si aucun argument n'est fourni, la version utilisée par défaut est Python 2.

- `NumberOfWorkers` – Nombre (entier).

Nombre de travaux d'un `workerType` défini qui sont alloués au point de terminaison de développement.

Le nombre maximal de travaux que vous pouvez définir est de 299 pour `G.1X` et de 149 pour `G.2X`.

- `NumberOfNodes` – Nombre (entier).

Le nombre d'unités de traitement des AWS Glue données (DPUs) allouées à `celaDevEndpoint`.

- `AvailabilityZone` – Chaîne UTF-8.

La zone de AWS disponibilité dans laquelle DevEndpoint il se trouve.

- VpcId – Chaîne UTF-8.

ID du cloud privé virtuel (VPC) utilisé par ce DevEndpoint.

- ExtraPythonLibsS3Path – Chaîne UTF-8.

Chemin(s) d'accès à une ou plusieurs bibliothèques Python dans un compartiment Amazon S3 qui doit être chargé dans votre DevEndpoint. Les valeurs doivent être des chemins entiers séparés par une virgule.

 Note

Vous pouvez uniquement utiliser des bibliothèques Python pur avec un DevEndpoint. Les bibliothèques reposant sur des extensions C, par exemple la bibliothèque d'analyse des données Python [pandas](#), ne sont actuellement pas prises en charge.

- ExtraJarsS3Path – Chaîne UTF-8.

Chemin d'accès à un ou plusieurs fichiers Java .jar dans un compartiment S3 qui doit être chargé dans votre DevEndpoint.

 Note

Vous pouvez uniquement utiliser des bibliothèques Java/Scala pures avec un DevEndpoint.

- FailureReason – Chaîne UTF-8.

Raison d'un échec actuel dans ce DevEndpoint.

- LastUpdateStatus – Chaîne UTF-8.

Statut de la dernière mise à jour.

- CreatedTimestamp – Horodatage.

Le moment où ce DevEndpoint a été créé.

- LastModifiedTimestamp – Horodatage.

Moment auquel ce DevEndpoint a été modifié pour la dernière fois.

- **PublicKey** – Chaîne UTF-8.

Clé publique à utiliser par ce DevEndpoint pour l'authentification. Cet attribut est fourni à des fins de rétrocompatibilité, car l'attribut dont l'utilisation est recommandée sont les clés publiques.

- **PublicKeys** – Tableau de chaînes UTF-8, avec 5 chaînes maximum.

Liste de clés publiques à utiliser par le DevEndpoints pour authentification. L'utilisation de cet attribut est plus recommandé qu'une simple clé publique, car les clés publiques vous permettent d'avoir une clé privée différente pour chaque client.

 Note

Si vous avez déjà créé un point de terminaison avec une clé publique, vous devez supprimer cette clé pour être en mesure de définir une liste de clés publiques. Appelez l'opération d'API `UpdateDevEndpoint` avec le contenu de la clé publique dans l'attribut `deletePublicKeys` et la liste des nouvelles clés dans l'attribut `addPublicKeys`.

- **SecurityConfiguration** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la structure `SecurityConfiguration` à utiliser avec ce DevEndpoint.

- **Arguments** – tableau de mappage de paires clé-valeur, avec 100 paires au maximum.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Mappage des arguments utilisés pour configurer le DevEndpoint.

Les arguments valides sont :

- `--enable-glue-datacatalog`: ""

Vous pouvez spécifier une version du support Python pour les points de terminaison de développement en utilisant le `Arguments` paramètre dans le `CreateDevEndpoint` ou `UpdateDevEndpoint` APIs. Si aucun argument n'est fourni, la version utilisée par défaut est Python 2.

DevEndpointCustomLibraries structure

Bibliothèques personnalisées à charger dans un point de terminaison de développement.

Champs

- `ExtraPythonLibsS3Path` – Chaîne UTF-8.

Chemins d'accès à une ou plusieurs bibliothèques Python dans un compartiment Amazon Simple Storage Service (Amazon S3) qui doivent être chargées dans votre `DevEndpoint`. Les valeurs doivent être des chemins entiers séparés par une virgule.

Note

Vous pouvez uniquement utiliser des bibliothèques Python pur avec un `DevEndpoint`. Les bibliothèques reposant sur des extensions C, par exemple la bibliothèque d'analyse des données Python [pandas](#), ne sont actuellement pas prises en charge.

- `ExtraJarsS3Path` – Chaîne UTF-8.

Chemin d'accès à un ou plusieurs fichiers Java `.jar` dans un compartiment S3 qui doit être chargé dans votre `DevEndpoint`.

Note

Vous pouvez uniquement utiliser des bibliothèques Java/Scala pures avec un `DevEndpoint`.

Opérations

- [CreateDevEndpoint action \(Python : `create\_dev\_endpoint`\)](#)
- [UpdateDevEndpoint action \(Python : `update\_dev\_endpoint`\)](#)
- [DeleteDevEndpoint action \(Python : `delete\_dev\_endpoint`\)](#)
- [GetDevEndpoint action \(Python : `get\_dev\_endpoint`\)](#)
- [GetDevEndpoints action \(Python : `get\_dev\_endpoints`\)](#)
- [BatchGetDevEndpoints action \(Python : `batch\_get\_dev\_endpoints`\)](#)

- [ListDevEndpoints action \(Python : list_dev_endpoints\)](#)

CreateDevEndpoint action (Python : create_dev_endpoint)

Crée un nouveau point de terminaison de développement.

Demande

- **EndpointName** – Obligatoire : chaîne UTF-8.

Nom à affecter au nouveau DevEndpoint.

- **RoleArn** – Obligatoire : Chaîne UTF-8, correspondant au [AWS IAM ARN string pattern](#).

Rôle IAM pour le DevEndpoint.

- **SecurityGroupIds** – Tableau de chaînes UTF-8.

Groupe de sécurité IDs pour les groupes de sécurité à utiliser par le nouveauDevEndpoint.

- **SubnetId** – Chaîne UTF-8.

ID de sous-réseau pour le nouveau DevEndpoint à utiliser.

- **PublicKey** – Chaîne UTF-8.

Clé publique à utiliser par ce DevEndpoint pour l'authentification. Cet attribut est fourni à des fins de rétrocompatibilité, car l'attribut dont l'utilisation est recommandée sont les clés publiques.

- **PublicKeys** – Tableau de chaînes UTF-8, avec 5 chaînes maximum.

Liste de clés publiques à utiliser par les points de terminaison de développement pour authentification. L'utilisation de cet attribut est plus recommandé qu'une simple clé publique, car les clés publiques vous permettent d'avoir une clé privée différente pour chaque client.

Note

Si vous avez déjà créé un point de terminaison avec une clé publique, vous devez supprimer cette clé pour être en mesure de définir une liste de clés publiques. Appelez l'API UpdateDevEndpoint avec le contenu de la clé publique dans l'attribut deletePublicKeys et la liste des nouvelles clés dans l'attribut addPublicKeys.

- **NumberOfNodes** – Nombre (entier).

Le nombre d'unités de traitement des AWS Glue données (DPUs) à y affecter `DevEndpoint`.

- `WorkerType` – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type de travail prédéfini qui est alloué au point de terminaison de développement. Accepte la valeur `Standard`, `G.1X` ou `G.2X`.

- Pour le type de travail `Standard`, chaque travail fournit 4 vCPU, 16 Go de mémoire et 50 Go de disque, ainsi que 2 exécuteurs par travail.
- Pour le type de travail `G.1X`, chaque travail mappe vers 1 DPU (4 vCPU, 16 Go de mémoire et 64 Go de disque), et fournit 1 exécuteur par travail. Nous vous recommandons ce type d'employé pour les tâches utilisant beaucoup de mémoire.
- Pour le type de travail `G.2X`, chaque travail mappe vers 2 DPU (8 vCPU, 32 Go de mémoire et 128 Go de disque), et fournit 1 exécuteur par travail. Nous vous recommandons ce type d'employé pour les tâches utilisant beaucoup de mémoire.

Problème connu : lorsqu'un point de terminaison de développement est créé avec la configuration `G.2X WorkerType`, les pilotes Spark pour le point de terminaison de développement s'exécutent sur 4 vCPU, 16 Go de mémoire et un disque de 64 Go.

- `GlueVersion` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

La version de Glue détermine les versions d'Apache Spark et Python prises AWS Glue en charge. La version de Python indique la version prise en charge pour l'exécution de vos scripts ETL sur les points de terminaison de développement.

Pour plus d'informations sur les AWS Glue versions disponibles et les versions correspondantes de Spark et Python, consultez [la version de Glue](#) dans le guide du développeur.

Les points de terminaison de développement créés sans spécifier une version de Glue utilisent par défaut Glue 0.9.

Vous pouvez spécifier une version du support Python pour les points de terminaison de développement en utilisant le `Arguments` paramètre dans le `CreateDevEndpoint` ou `UpdateDevEndpoint` APIs. Si aucun argument n'est fourni, la version utilisée par défaut est Python 2.

- `NumberOfWorkers` – Nombre (entier).

Nombre de travaux d'un `workerType` défini qui sont alloués au point de terminaison de développement.

Le nombre maximal de travaux que vous pouvez définir est de 299 pour `G.1X` et de 149 pour `G.2X`.

- `ExtraPythonLibsS3Path` – Chaîne UTF-8.

Chemin(s) d'accès à une ou plusieurs bibliothèques Python dans un compartiment Amazon S3 qui doit être chargé dans votre `DevEndpoint`. Les valeurs doivent être des chemins entiers séparés par une virgule.

 Note

Vous pouvez uniquement utiliser des bibliothèques Python pur avec un `DevEndpoint`. Les bibliothèques reposant sur des extensions C, par exemple la bibliothèque d'analyse des données Python [pandas](#), ne sont pas encore prises en charge.

- `ExtraJarsS3Path` – Chaîne UTF-8.

Chemin d'accès à un ou plusieurs fichiers Java `.jar` dans un compartiment S3 qui doit être chargé dans votre `DevEndpoint`.

- `SecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la structure `SecurityConfiguration` à utiliser avec ce `DevEndpoint`.

- `Tags` – tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Balises à utiliser avec ce `DevEndpoint`. Vous pouvez utiliser des balises pour limiter l'accès au `DevEndpoint`. Pour plus d'informations sur les tags in AWS Glue, voir [AWS Tags in AWS Glue](#) dans le guide du développeur.

- `Arguments` – tableau de mappage de paires clé-valeur, avec 100 paires au maximum.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Mappage des arguments utilisés pour configurer le DevEndpoint.

Réponse

- `EndpointName` – Chaîne UTF-8.

Nom attribué au nouveau DevEndpoint.

- `Status` – Chaîne UTF-8.

Statut actuel du nouveau DevEndpoint.

- `SecurityGroupIds` – Tableau de chaînes UTF-8.

Groupes de sécurité affectés au nouveau DevEndpoint.

- `SubnetId` – Chaîne UTF-8.

ID de sous-réseau affecté au nouveau DevEndpoint.

- `RoleArn` – Chaîne UTF-8, correspondant au [AWS IAM ARN string pattern](#).

Amazon Resource Name (ARN) du rôle affecté au nouveau DevEndpoint.

- `YarnEndpointAddress` – Chaîne UTF-8.

Adresse du point de terminaison YARN utilisé par ce DevEndpoint.

- `ZeppelinRemoteSparkInterpreterPort` – Nombre (entier).

Port Apache Zeppelin pour l'interpréteur Apache Spark à distance.

- `NumberOfNodes` – Nombre (entier).

Le nombre d'unités de traitement des AWS Glue données (DPUs) allouées à cela DevEndpoint.

- `WorkerType` – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type de travail prédéfini qui est alloué au point de terminaison de développement. La valeur peut être `Standard`, `G.1X` ou `G.2X`.

- `GlueVersion` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

La version de Glue détermine les versions d'Apache Spark et Python prises en charge par AWS Glue. La version de Python indique la version prise en charge pour l'exécution de vos scripts ETL sur les points de terminaison de développement.

Pour plus d'informations sur les versions AWS Glue disponibles et les versions correspondantes de Spark et Python, consultez [la version de Glue](#) dans le guide du développeur.

- `NumberOfWorkers` – Nombre (entier).

Nombre de travaux d'un `workerType` défini qui sont alloués au point de terminaison de développement.

- `AvailabilityZone` – Chaîne UTF-8.

La zone de disponibilité AWS dans laquelle `DevEndpoint` se trouve.

- `VpcId` – Chaîne UTF-8.

ID du cloud privé virtuel (VPC) utilisé par ce `DevEndpoint`.

- `ExtraPythonLibsS3Path` – Chaîne UTF-8.

Chemin(s) d'accès à une ou plusieurs bibliothèques Python dans un compartiment S3 qui sera chargé dans votre `DevEndpoint`.

- `ExtraJarsS3Path` – Chaîne UTF-8.

Chemin(s) d'accès à un ou plusieurs fichiers Java `.jar` dans un compartiment S3 qui sera chargé dans votre `DevEndpoint`.

- `FailureReason` – Chaîne UTF-8.

Raison d'un échec actuel dans ce `DevEndpoint`.

- `SecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la structure `SecurityConfiguration` utilisée avec ce `DevEndpoint`.

- `CreatedTimestamp` – Horodatage.

Moment où ce `DevEndpoint` a été créé.

- `Arguments` – tableau de mappage de paires clé-valeur, avec 100 paires au maximum.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Mappage des arguments utilisés pour configurer ce DevEndpoint.

Les arguments valides sont :

- "--enable-glue-datacatalog": ""

Vous pouvez spécifier une version du support Python pour les points de terminaison de développement en utilisant le Arguments paramètre dans le CreateDevEndpoint ou UpdateDevEndpoint APIs. Si aucun argument n'est fourni, la version utilisée par défaut est Python 2.

Erreurs

- AccessDeniedException
- AlreadyExistsException
- IdempotentParameterMismatchException
- InternalServiceException
- OperationTimeoutException
- InvalidInputException
- ValidationException
- ResourceNumberLimitExceededException

UpdateDevEndpoint action (Python : update_dev_endpoint)

Met à jour un point de terminaison de développement spécifié.

Demande

- EndpointName – Obligatoire : chaîne UTF-8.

Nom du DevEndpoint à mettre à jour.

- PublicKey – Chaîne UTF-8.

Clé publique pour le DevEndpoint à utiliser.

- AddPublicKeys – Tableau de chaînes UTF-8, avec 5 chaînes maximum.

Liste des clés publiques pour le DevEndpoint à utiliser.

- `DeletePublicKeys` – Tableau de chaînes UTF-8, avec 5 chaînes maximum.

Liste de clés publiques à supprimer du DevEndpoint.

- `CustomLibraries` – Un objet [DevEndpointCustomLibraries](#).

Bibliothèques Python ou Java personnalisées à charger dans le DevEndpoint.

- `UpdateEtlLibraries` – Booléen.

True si la liste des bibliothèques personnalisées à charger dans le point de terminaison de développement doit être mise à jour, sinon False.

- `DeleteArguments` – Tableau de chaînes UTF-8.

Liste des clés d'argument à supprimer du mappage d'arguments utilisé pour configurer le DevEndpoint.

- `AddArguments` – tableau de mappage de paires clé-valeur, avec 100 paires au maximum.

Chaque clé est une chaîne UTF-8.

Chaque valeur est une chaîne UTF-8.

Mappage d'arguments à ajouter au mappage d'arguments utilisé pour configurer le DevEndpoint.

Les arguments valides sont :

- `--enable-glue-datacatalog`: ""

Vous pouvez spécifier une version du support Python pour les points de terminaison de développement en utilisant le `Arguments` paramètre dans le `CreateDevEndpoint` ou `UpdateDevEndpoint` APIs. Si aucun argument n'est fourni, la version utilisée par défaut est Python 2.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ValidationException`

DeleteDevEndpoint action (Python : `delete_dev_endpoint`)

Supprime un point de terminaison de développement spécifié.

Demande

- `EndpointName` – Obligatoire : chaîne UTF-8.

Le nom de l'`DevEndpoint`.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

GetDevEndpoint action (Python : `get_dev_endpoint`)

Récupère des informations sur un point de terminaison de développement spécifié.

Note

Lorsque vous créez un point de terminaison de développement dans un cloud privé virtuel (VPC), AWS Glue renvoie uniquement une adresse IP privée et le champ de l'adresse IP

publique n'est pas renseigné. Lorsque vous créez un point de terminaison de développement non VPC, il AWS Glue renvoie uniquement une adresse IP publique.

Demande

- **EndpointName** – Obligatoire : chaîne UTF-8.

Nom du DevEndpoint pour lequel des informations seront récupérées.

Réponse

- **DevEndpoint** – Un objet [DevEndpoint](#).

Définition d'un DevEndpoint.

Erreurs

- **EntityNotFoundException**
- **InternalServiceException**
- **OperationTimeoutException**
- **InvalidInputException**

GetDevEndpoints action (Python : `get_dev_endpoints`)

Récupère tous les points de terminaison de développement de ce AWS compte.

Note

Lorsque vous créez un point de terminaison de développement dans un Virtual Private Cloud (VPC), AWS Glue renvoie uniquement une adresse IP privée et le champ de l'adresse IP publique n'est pas renseigné. Lorsque vous créez un point de terminaison de développement non VPC, il AWS Glue renvoie uniquement une adresse IP publique.

Demande

- **MaxResults** – Nombre (entier), compris entre 1 et 1 000.

Taille maximale des informations à renvoyer.

- NextToken – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- DevEndpoints – Un tableau d'objets [DevEndpoint](#).

Liste des définitions de DevEndpoint.

- NextToken – Chaîne UTF-8.

Jeton de continuation, si toutes les définitions de DevEndpoint n'ont pas encore été renvoyées.

Erreurs

- EntityNotFoundException
- InternalServiceException
- OperationTimeoutException
- InvalidInputException

BatchGetDevEndpoints action (Python : batch_get_dev_endpoints)

Renvoie une liste des métadonnées de ressource pour une liste donnée de noms de point de terminaison de développement. Après avoir appelé l'opération ListDevEndpoints, vous pouvez appeler cette opération pour accéder aux données sur lesquelles des autorisations vous ont été octroyées. Cette opération prend en charge toutes les autorisations IAM, y compris les conditions d'autorisation qui utilisent des balises.

Demande

- customerAccountId – Chaîne UTF-8.

L'identifiant AWS du compte.

- DevEndpointNames – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 25 chaînes maximum.

Liste de noms de DevEndpoint, qui peuvent être les noms renvoyés à partir de l'opération `ListDevEndpoint`.

Réponse

- `DevEndpoints` – Un tableau d'objets [DevEndpoint](#).

Liste des définitions de DevEndpoint.

- `DevEndpointsNotFound` – tableau de chaînes UTF-8, avec 1 chaîne minimum et 25 chaînes maximum.

Liste des DevEndpoints introuvables.

Erreurs

- `AccessDeniedException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

ListDevEndpoints action (Python : `list_dev_endpoints`)

Récupère les noms de toutes les ressources DevEndpoint dans ce compte AWS , ou les ressources avec la balise spécifiée. Cette opération vous permet de voir quelles ressources sont disponibles dans votre compte, et leurs noms.

Cette opération accepte le champ `Tags` facultatif que vous pouvez utiliser comme filtre sur la réponse, afin que les ressources balisées puissent être récupérées en tant que groupe. Si vous choisissez d'utiliser le filtrage des balises, seules les ressources avec la balise sont récupérées.

Demande

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'une requête de continuation.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

La taille maximale d'une liste à renvoyer.

- **Tags** – tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Spécifie de renvoyer uniquement les ressources balisées.

Réponse

- **DevEndpointNames** – Tableau de chaînes UTF-8.

Noms de tous les **DevEndpoint** dans le compte ou les **DevEndpoint** avec les balises spécifiées.

- **NextToken** – Chaîne UTF-8.

Jeton continuation, si la liste renvoyée ne contient pas la dernière métrique disponible.

Erreurs

- **InvalidInputException**
- **EntityNotFoundException**
- **InternalServiceException**
- **OperationTimeoutException**

Registre de schémas

L'API de registre des schémas décrit les types de données et l'API liés à l'utilisation des schémas dans AWS Glue.

Types de données

- [RegistryId structure](#)
- [RegistryListItem structure](#)
- [MetadataInfo structure](#)
- [OtherMetadataValueListItem structure](#)

- [SchemaListItem structure](#)
- [SchemaVersionListItem structure](#)
- [MetadataKeyValuePair structure](#)
- [SchemaVersionErrorItem structure](#)
- [ErrorDetails structure](#)
- [SchemaVersionNumber structure](#)
- [Schemald structure](#)

RegistryId structure

Structure d'encapsulation qui peut contenir le nom et l'Amazon Resource Name (ARN) du registre.

Champs

- **RegistryName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre. Utilisé uniquement pour la recherche. RegistryArn ou RegistryName doit être fourni.

- **RegistryArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

ARN du registre à mettre à jour. RegistryArn ou RegistryName doit être fourni.

RegistryListItem structure

Une structure contenant les détails d'un registre.

Champs

- **RegistryName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre.

- **RegistryArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'Amazon Resource Name (ARN) du registre.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du registre.

- **Status** – Chaîne UTF-8 (valeurs valides : AVAILABLE | DELETING).

Statut du registre.

- **CreateTime** – Chaîne UTF-8.

Données que le registre a été créé.

- **UpdateTime** – Chaîne UTF-8.

Date à laquelle le registre a été mis à jour.

MetadataInfo structure

Structure contenant des informations de métadonnées pour une version de schéma.

Champs

- **MetadataValue** – Chaîne UTF-8, d'une longueur comprise entre 1 et 256 octets, correspondant au [Custom string pattern #14](#).

Valeur correspondant à une clé de métadonnées.

- **CreateTime** – Chaîne UTF-8.

Heure à laquelle l'entrée a été créée.

- **OtherMetadataValueList** – Un tableau d'objets [OtherMetadataValueListItem](#).

Autres métadonnées appartenant à la même clé de métadonnées.

OtherMetadataValueListItem structure

Structure contenant d'autres métadonnées pour une version de schéma appartenant à la même clé de métadonnées.

Champs

- **MetadataValue** – Chaîne UTF-8, d'une longueur comprise entre 1 et 256 octets, correspondant au [Custom string pattern #14](#).

Valeur correspondante de la clé de métadonnées pour les autres métadonnées appartenant à la même clé de métadonnées.

- **CreateTime** – Chaîne UTF-8.

Heure à laquelle l'entrée a été créée.

SchemaListItem structure

Objet qui contient des détails minimaux pour un schéma.

Champs

- **RegistryName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre dans lequel se trouve le schéma.

- **SchemaName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du schéma.

- **SchemaArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

Amazon Resource Name (ARN) du schéma.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du schéma.

- **SchemaStatus** – Chaîne UTF-8 (valeurs valides : AVAILABLE | PENDING | DELETING).

Statut du schéma.

- **CreateTime** – Chaîne UTF-8.

Date et heure de création d'un schéma.

- `UpdateTime` – Chaîne UTF-8.

Date et heure de mise à jour d'un schéma.

SchemaVersionListItem structure

Objet contenant les détails d'une version de schéma.

Champs

- `SchemaArn` – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'Amazon Resource Name (ARN) du filtre.

- `SchemaVersionId` – Chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

Identifiant unique de la version du schéma.

- `VersionNumber` – Nombre (long), compris entre 1 et 100 000.

Numéro de version du schéma.

- `Status` – Chaîne UTF-8 (valeurs valides : AVAILABLE | PENDING | FAILURE | DELETING).

Statut de la version du schéma.

- `CreateTime` – Chaîne UTF-8.

Date et heure de création à laquelle la version de schéma a été créée.

MetadataKeyValuePair structure

Structure contenant une paire de valeurs clé pour les métadonnées.

Champs

- `MetadataKey` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #14](#).

Clé de métadonnées.

- `MetadataValue` – Chaîne UTF-8, d'une longueur comprise entre 1 et 256 octets, correspondant au [Custom string pattern #14](#).

Valeur correspondant à une clé de métadonnées.

SchemaVersionErrorItem structure

Objet contenant les détails d'erreur d'une opération sur une version de schéma.

Champs

- `VersionNumber` – Nombre (long), compris entre 1 et 100 000.

Numéro de version du schéma.

- `ErrorDetails` – Un objet [ErrorDetails](#).

Détails de l'erreur pour la version du schéma.

ErrorDetails structure

Objet contenant des détails d'erreur.

Champs

- `ErrorCode` – Chaîne UTF-8.

Code d'erreur correspondant à une erreur.

- `ErrorMessage` – Chaîne UTF-8.

Message d'erreur pour une erreur.

SchemaVersionNumber structure

Structure contenant les informations de version du schéma.

Champs

- `LatestVersion` – Booléen.

Dernière version disponible pour le schéma.

- `VersionNumber` – Nombre (long), compris entre 1 et 100 000.

Numéro de version du schéma.

Schemald structure

ID unique du schéma dans le registre des AWS Glue schémas.

Champs

- `SchemaArn` – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'Amazon Resource Name (ARN) du filtre. `SchemaArn` ou `SchemaName` doit être fourni.

- `SchemaName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du schéma. `SchemaArn` ou `SchemaName` doit être fourni.

- `RegistryName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre de schémas contenant le schéma.

Opérations

- [CreateRegistry action \(Python : `create\_registry`\)](#)
- [CreateSchema action \(Python : `créer\_schéma`\)](#)
- [GetSchema action \(Python : `get\_schema`\)](#)
- [ListSchemaVersions action \(Python : `list\_schema\_versions`\)](#)
- [GetSchemaVersion action \(Python : `get\_schema\_version`\)](#)
- [GetSchemaVersionsDiff action \(Python : `get\_schema\_versions\_diff`\)](#)
- [ListRegistries action \(Python : `list\_registries`\)](#)
- [ListSchemas action \(Python : `list\_schemas`\)](#)
- [RegisterSchemaVersion action \(Python : `register\_schema\_version`\)](#)
- [UpdateSchema action \(Python : `update\_schema`\)](#)

- [CheckSchemaVersionValidity](#) action (Python : `check_schema_version_validity`)
- [UpdateRegistry](#) action (Python : `update_registry`)
- [GetSchemaByDefinition](#) action (Python : `get_schema_by_definition`)
- [GetRegistry](#) action (Python : `get_registry`)
- [PutSchemaVersionMetadata](#) action (Python : `put_schema_version_metadata`)
- [QuerySchemaVersionMetadata](#) action (Python : `query_schema_version_metadata`)
- [RemoveSchemaVersionMetadata](#) action (Python : `remove_schema_version_metadata`)
- [DeleteRegistry](#) action (Python : `supprimer_registre`)
- [DeleteSchema](#) action (Python : `supprimer_schéma`)
- [DeleteSchemaVersions](#) action (Python : `delete_schema_versions`)

CreateRegistry action (Python : `create_registry`)

Crée un registre qui peut être utilisé pour contenir une collection de schémas.

Demande

- **RegistryName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre à créer, d'une longueur maximale de 255, et ne pouvant contenir que des lettres, des chiffres, trait d'union, trait de soulignement, symbole dollar ou dièse. Pas d'espace.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du registre. Si la description n'est pas fournie, aucune valeur par défaut ne sera attribuée.

- **Tags** – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

AWS balises contenant une paire clé-valeur et pouvant être recherchées par console, ligne de commande ou API.

Réponse

- **RegistryArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

Amazon Resource Name (ARN) du registre nouvellement créé.

- **RegistryName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du registre.

- **Tags** – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Balises pour le registre.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`
- `InternalServiceException`

CreateSchema action (Python : créer_schéma)

Crée un jeu de schémas et enregistre la définition de schéma. Renvoie une erreur si le jeu de schémas existe déjà sans pour autant enregistrer la version.

Lorsque le jeu de schémas est créé, un point de contrôle de version est défini sur la première version. Le mode de compatibilité « DISABLED » empêche toute version de schéma supplémentaire d'être ajoutée après la première version de schéma. Pour tous les autres modes de compatibilité, la validation des paramètres de compatibilité ne sera appliquée qu'à partir de la deuxième version lorsque l'API `RegisterSchemaVersion` est utilisée.

Lorsque cette API est appelée sans `RegistryId`, cela créera une entrée pour un « registre par défaut » dans les tables de base de données du registre, si elle n'est pas déjà présente.

Demande

- `RegistryId` – Un objet [RegistryId](#).

Il s'agit d'une forme d'encapsulation qui contient les champs d'identité du registre. S'il n'est pas fourni, le registre par défaut sera utilisé. Le format ARN pour celui-ci sera : `arn:aws:glue:us-east-2:<customer id>:registry/default-registry:random-5-letter-id`.

- `SchemaName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du schéma à créer d'une longueur maximale de 255. Il ne peut contenir que des lettres, chiffres, tirets, traits de soulignement, signes dollar ou signes de hachage. Pas d'espace.

- `DataFormat` – Obligatoire : Chaîne UTF-8 (valeurs valides : `AVRO` | `JSON` | `PROTOBUF`).

Format de données de la définition de schéma. À l'heure actuelle, `AVRO`, `JSON` et `PROTOBUF` sont pris en charge.

- `Compatibility` – Chaîne UTF-8 (valeurs valides : `NONE` | `DISABLED` | `BACKWARD` | `BACKWARD_ALL` | `FORWARD` | `FORWARD_ALL` | `FULL` | `FULL_ALL`).

Mode de compatibilité du schéma. Les valeurs possibles sont :

- `NONE` (AUCUN) : aucun mode de compatibilité ne s'applique. Vous pouvez utiliser ce choix dans les scénarios de développement ou si vous ne connaissez pas le mode de compatibilité que vous souhaitez appliquer aux schémas. Toute nouvelle version ajoutée sera acceptée sans faire l'objet d'un contrôle de compatibilité.
- `DISABLED` (DÉSACTIVÉ) : ce choix de compatibilité empêche la gestion des versions pour un schéma particulier. Vous pouvez utiliser ce choix pour empêcher la gestion des versions futures d'un schéma.
- `BACKWARD` (DESCENDANT) : ce choix de compatibilité est recommandé, car il permet aux récepteurs de données de lire à la fois la version actuelle et une version antérieure du schéma.

Cela signifie, par exemple, qu'une nouvelle version de schéma ne peut pas supprimer des champs de données ou modifier le type de ces champs, de sorte qu'ils ne peuvent pas être lus par les lecteurs utilisant la version précédente.

- **BACKWARD_ALL (DESCENDANT_TOUT)** : ce choix de compatibilité permet aux récepteurs de données de lire à la fois la version actuelle et toutes les versions antérieures du schéma. Vous pouvez utiliser ce choix lorsque vous devez supprimer des champs ou ajouter des champs facultatifs, et vérifier la compatibilité avec toutes les versions de schéma précédentes.
- **ASCENDANT** : ce choix de compatibilité permet aux récepteurs de données de lire à la fois la version actuelle et la version suivante du schéma, mais pas nécessairement les versions ultérieures. Vous pouvez utiliser ce choix lorsque vous devez ajouter des champs ou supprimer des champs facultatifs, mais uniquement vérifier la compatibilité avec la dernière version du schéma.
- **ASCENDANT_TOUT** : ce choix de compatibilité permet aux récepteurs de données de lire les données écrites par les producteurs de tout nouveau schéma enregistré. Vous pouvez utiliser ce choix lorsque vous devez ajouter des champs ou supprimer des champs facultatifs, et vérifier la compatibilité avec toutes les versions de schéma précédentes.
- **COMPLET** : ce choix de compatibilité permet aux récepteurs de données de lire les données écrites par les producteurs à l'aide de la version précédente ou suivante du schéma, mais pas nécessairement des versions antérieures ou ultérieures. Vous pouvez utiliser ce choix lorsque vous devez ajouter ou supprimer des champs facultatifs, mais uniquement vérifier la compatibilité par rapport à la dernière version du schéma.
- **COMPLET_TOUT** : ce choix de compatibilité permet aux récepteurs de données de lire les données écrites par les producteurs utilisant toutes les versions de schéma précédentes. Vous pouvez utiliser ce choix lorsque vous devez ajouter ou supprimer des champs facultatifs et vérifier la compatibilité avec toutes les versions de schéma précédentes.
- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description facultative du schéma. Si la description n'est pas fournie, aucune valeur par défaut ne sera attribuée automatiquement.

- **Tags** – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

AWS balises contenant une paire clé-valeur et pouvant être recherchées par console, ligne de commande ou API. Si spécifié, suit le AWS tags-on-create modèle.

- **SchemaDefinition** – Chaîne UTF-8, d'une longueur comprise entre 1 et 170 000 octets, correspondant au [Custom string pattern #13](#).

Définition de schéma à l'aide du paramètre DataFormat pour SchemaName.

Réponse

- **RegistryName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre.

- **RegistryArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'Amazon Resource Name (ARN) du registre.

- **SchemaName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du schéma.

- **SchemaArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'Amazon Resource Name (ARN) du filtre.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du schéma si spécifié lors de sa création.

- **DataFormat** – Chaîne UTF-8 (valeurs valides : AVRO | JSON | PROTOBUF).

Format de données de la définition de schéma. À l'heure actuelle, AVRO, JSON et PROTOBUF sont pris en charge.

- **Compatibility** – Chaîne UTF-8 (valeurs valides : NONE | DISABLED | BACKWARD | BACKWARD_ALL | FORWARD | FORWARD_ALL | FULL | FULL_ALL).

Mode de compatibilité du schéma.

- `SchemaCheckpoint` – Nombre (long), compris entre 1 et 100 000.

Numéro de version du point de contrôle (la dernière fois que le mode de compatibilité a été modifié).

- `LatestSchemaVersion` – Nombre (long), compris entre 1 et 100 000.

Version la plus récente du schéma associé à la définition de schéma renvoyée.

- `NextSchemaVersion` – Nombre (long), compris entre 1 et 100 000.

Version suivante du schéma associé à la définition de schéma renvoyée.

- `SchemaStatus` – Chaîne UTF-8 (valeurs valides : AVAILABLE | PENDING | DELETING).

Statut du schéma.

- `Tags` – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Balises pour le schéma.

- `SchemaVersionId` – Chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

Identifiant unique de la première version du schéma.

- `SchemaVersionStatus` – Chaîne UTF-8 (valeurs valides : AVAILABLE | PENDING | FAILURE | DELETING).

Statut de la première version du schéma créée.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`

- `InternalServiceException`

GetSchema action (Python : `get_schema`)

Décrit en détail le schéma spécifié.

Demande

- `SchemaId` – Obligatoire : un objet [Schemald](#).

Structure d'encapsulation contenant les champs d'identité de schéma. La structure contient :

- `Schemald$ SchemaArn` : Le nom de ressource Amazon (ARN) du schéma. Il faut fournir soit `SchemaArn`, soit `SchemaName` et `RegistryName`.
- `Schemald$ SchemaName` : nom du schéma. Il faut fournir soit `SchemaArn`, soit `SchemaName` et `RegistryName`.

Réponse

- `RegistryName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre.

- `RegistryArn` – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'Amazon Resource Name (ARN) du registre.

- `SchemaName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du schéma.

- `SchemaArn` – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'Amazon Resource Name (ARN) du filtre.

- `Description` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du schéma si spécifié lors de sa création

- `DataFormat` – Chaîne UTF-8 (valeurs valides : AVRO | JSON | PROTOBUF).

Format de données de la définition de schéma. À l'heure actuelle, AVRO, JSON et PROTOBUF sont pris en charge.

- `Compatibility` – Chaîne UTF-8 (valeurs valides : NONE | DISABLED | BACKWARD | BACKWARD_ALL | FORWARD | FORWARD_ALL | FULL | FULL_ALL).

Mode de compatibilité du schéma.

- `SchemaCheckpoint` – Nombre (long), compris entre 1 et 100 000.

Numéro de version du point de contrôle (la dernière fois que le mode de compatibilité a été modifié).

- `LatestSchemaVersion` – Nombre (long), compris entre 1 et 100 000.

Version la plus récente du schéma associé à la définition de schéma renvoyée.

- `NextSchemaVersion` – Nombre (long), compris entre 1 et 100 000.

Version suivante du schéma associé à la définition de schéma renvoyée.

- `SchemaStatus` – Chaîne UTF-8 (valeurs valides : AVAILABLE | PENDING | DELETING).

Statut du schéma.

- `CreatedTime` – Chaîne UTF-8.

Date et heure de création du schéma.

- `UpdatedTime` – Chaîne UTF-8.

Date et heure de mise à jour du schéma.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`

ListSchemaVersions action (Python : list_schema_versions)

Renvoie une liste des versions de schéma que vous avez créées, avec un minimum d'informations. Les versions de schémas dont le statut est Deleted ne seront pas incluses dans les résultats. Des résultats vides seront retournés s'il n'y a pas de version de schéma disponible.

Demande

- SchemaId – Obligatoire : un objet [Schemald](#).

Structure d'encapsulation contenant les champs d'identité de schéma. La structure contient :

- Schemald\$ SchemaArn : Le nom de ressource Amazon (ARN) du schéma. Il faut fournir soit SchemaArn, soit SchemaName et RegistryName.
- Schemald\$ SchemaName : nom du schéma. Il faut fournir soit SchemaArn, soit SchemaName et RegistryName.
- MaxResults – Nombre (entier), compris entre 1 et 100.

Nombre maximum de résultats requis par page. Si la valeur n'est pas fournie, elle par défaut sera de 25 par page.

- NextToken – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- Schemas – Un tableau d'objets [SchemaVersionListItem](#).

Tableau d'objets SchemaVersionList contenant les détails de chaque version de schéma.

- NextToken – Chaîne UTF-8.

Jeton de continuation pour la pagination de la liste des jetons renvoyés, renvoyé si le segment actuel de la liste n'est pas le dernier.

Erreurs

- InvalidInputException
- AccessDeniedException
- EntityNotFoundException

- `InternalServiceException`

GetSchemaVersion action (Python : `get_schema_version`)

Récupère le schéma spécifié par son ID unique attribué lors de la création ou de l'enregistrement d'une version du schéma. Les versions de schémas dont le statut est Deleted ne seront pas incluses dans les résultats.

Demande

- `SchemaId` – Un objet [Schemald](#).

Structure d'encapsulation contenant les champs d'identité de schéma. La structure contient :

- `Schemald$ SchemaArn` : Le nom de ressource Amazon (ARN) du schéma. Il faut fournir soit `SchemaArn`, soit `SchemaName` et `RegistryName`.
- `Schemald$ SchemaName` : nom du schéma. Il faut fournir soit `SchemaArn`, soit `SchemaName` et `RegistryName`.
- `SchemaVersionId` – Chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

Le `SchemaVersionId` de la version du schéma. Ce champ est requis pour l'extraction par ID de schéma. Il faut fournir soit cet élément, soit l'encapsulateur `SchemaId`.

- `SchemaVersionNumber` – Un objet [SchemaVersionNumber](#).

Numéro de version du schéma.

Réponse

- `SchemaVersionId` – Chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

Le `SchemaVersionId` de la version du schéma.

- `SchemaDefinition` – Chaîne UTF-8, d'une longueur comprise entre 1 et 170 000 octets, correspondant au [Custom string pattern #13](#).

La définition du schéma pour l'ID du schéma.

- `DataFormat` – Chaîne UTF-8 (valeurs valides : AVRO | JSON | PROTOBUF).

Format de données de la définition de schéma. À l'heure actuelle, AVRO, JSON et PROTOBUF sont pris en charge.

- `SchemaArn` – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'Amazon Resource Name (ARN) du filtre.

- `VersionNumber` – Nombre (long), compris entre 1 et 100 000.

Numéro de version du schéma.

- `Status` – Chaîne UTF-8 (valeurs valides : AVAILABLE | PENDING | FAILURE | DELETING).

Statut de la version du schéma.

- `CreateTime` – Chaîne UTF-8.

Date et heure de création à laquelle la version de schéma a été créée.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`

GetSchemaVersionsDiff action (Python : `get_schema_versions_diff`)

Récupère la différence de version de schéma dans le type de différence spécifié entre deux versions de schéma stockées dans le registre des schémas.

Cette API vous permet de comparer deux versions de schéma entre deux définitions de schéma sous le même schéma.

Demande

- `SchemaId` – Obligatoire : un objet [Schemald](#).

Structure d'encapsulation contenant les champs d'identité de schéma. La structure contient :

- `Schemald$ SchemaArn` : Le nom de ressource Amazon (ARN) du schéma. `SchemaArn` ou `SchemaName` doit être fourni.
- `Schemald$ SchemaName` : nom du schéma. `SchemaArn` ou `SchemaName` doit être fourni.
- `FirstSchemaVersionNumber` – Obligatoire : un objet [SchemaVersionNumber](#).

La première des deux versions de schéma à comparer.

- `SecondSchemaVersionNumber` – Obligatoire : un objet [SchemaVersionNumber](#).

La seconde des deux versions de schéma à comparer.

- `SchemaDiffType` – Obligatoire : Chaîne UTF-8 (valeurs valides : `SYNTAX_DIFF`).

Fait référence à `SYNTAX_DIFF`, qui est le type diff actuellement pris en charge.

Réponse

- `Diff` – Chaîne UTF-8, d'une longueur comprise entre 1 et 340 000 octets, correspondant au [Custom string pattern #13](#).

La différence entre les schémas sous forme de chaîne de JsonPatch caractères.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `AccessDeniedException`
- `InternalServiceException`

ListRegistries action (Python : `list_registries`)

Renvoie une liste des registres que vous avez créés, avec des informations de registre minimales. Les registres dont le statut est `Deleting` ne seront pas inclus dans les résultats. Des résultats vides seront retournés s'il n'y a pas de registres disponibles.

Demande

- `MaxResults` – Nombre (entier), compris entre 1 et 100.

Nombre maximum de résultats requis par page. Si la valeur n'est pas fournie, elle par défaut sera de 25 par page.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- `Registries` – Un tableau d'objets [RegistryListItem](#).

Tableau d'objets `RegistryDetailedListItem` contenant des détails minimaux de chaque registre.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation pour la pagination de la liste des jetons renvoyés, renvoyé si le segment actuel de la liste n'est pas le dernier.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `InternalServiceException`

ListSchemas action (Python : `list_schemas`)

Renvoie une liste de schémas avec des détails minimaux. Les schémas dont le statut est `Deleted` ne seront pas inclus dans les résultats. Des résultats vides seront retournés s'il n'y a pas de schéma disponible.

Lorsque `RegistryId` n'est pas fourni, tous les schémas entre les registres feront partie de la réponse de l'API.

Demande

- `RegistryId` – Un objet [RegistryId](#).

Structure d'encapsulation qui peut contenir le nom et l'Amazon Resource Name (ARN) du registre.

- `MaxResults` – Nombre (entier), compris entre 1 et 100.

Nombre maximum de résultats requis par page. Si la valeur n'est pas fournie, elle par défaut sera de 25 par page.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- `Schemas` – Un tableau d'objets [SchemaListItem](#).

Tableau d'objets `SchemaListItem` contenant les détails de chaque schéma.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation pour la pagination de la liste des jetons renvoyés, renvoyé si le segment actuel de la liste n'est pas le dernier.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`

RegisterSchemaVersion action (Python : `register_schema_version`)

Ajoute une nouvelle version au schéma existant. Renvoie une erreur si la nouvelle version du schéma ne répond pas aux exigences de compatibilité du jeu de schémas. Cette API ne crée pas de nouveau jeu de schémas et renvoie une erreur 404 si le jeu de schémas n'est pas déjà présent dans le registre de schémas.

S'il s'agit de la première définition de schéma enregistrée dans le registre de schéma, cette API stockera la version du schéma et retournera immédiatement à l'appelant. Sinon, cet appel peut s'exécuter plus longtemps que d'autres opérations en raison des modes de compatibilité. Vous pouvez appeler l'API `GetSchemaVersion` avec le `SchemaVersionId` pour vérifier les modes de compatibilité.

Si la même définition de schéma est déjà stockée dans le registre de schéma en tant que version, l'ID de schéma du schéma existant est renvoyé à l'appelant.

Demande

- `SchemaId` – Obligatoire : un objet [Schemald](#).

Structure d'encapsulation contenant les champs d'identité de schéma. La structure contient :

- `Schemald$ SchemaArn` : Le nom de ressource Amazon (ARN) du schéma. Il faut fournir soit `SchemaArn`, soit `SchemaName` et `RegistryName`.
- `Schemald$ SchemaName` : nom du schéma. Il faut fournir soit `SchemaArn`, soit `SchemaName` et `RegistryName`.
- `SchemaDefinition` – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 170 000 octets, correspondant au [Custom string pattern #13](#).

Définition de schéma à l'aide du paramètre `DataFormat` pour `SchemaName`.

Réponse

- `SchemaVersionId` – Chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

ID unique qui représente la version de ce schéma.

- `VersionNumber` – Nombre (long), compris entre 1 et 100 000.

Version de ce schéma (pour le flux de synchronisation uniquement, dans le cas où il s'agit de la première version).

- `Status` – Chaîne UTF-8 (valeurs valides : `AVAILABLE` | `PENDING` | `FAILURE` | `DELETING`).

Statut de la version du schéma.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ResourceNumberLimitExceededException`

- `ConcurrentModificationException`
- `InternalServiceException`

UpdateSchema action (Python : `update_schema`)

Met à jour la description, le paramètre de compatibilité ou le point de contrôle de version d'un jeu de schéma.

Pour mettre à jour le paramètre de compatibilité, l'appel ne valide pas la compatibilité pour l'ensemble des versions de schéma avec le nouveau paramètre de compatibilité. Si la valeur pour `Compatibility` est fournie, le `VersionNumber` (un point de contrôle) est également requis. L'API valide le numéro de version du point de contrôle à des fins de cohérence.

Si la valeur pour `VersionNumber` (point de contrôle) est fournie, `Compatibility` est facultatif et cela peut être utilisé pour définir/réinitialiser un point de contrôle pour le schéma.

Cette mise à jour se produira uniquement si le schéma est dans l'état AVAILABLE (DISPONIBLE).

Demande

- `SchemaId` – Obligatoire : un objet [Schemald](#).

Structure d'encapsulation contenant les champs d'identité de schéma. La structure contient :

- `Schemald$ SchemaArn` : Le nom de ressource Amazon (ARN) du schéma. `SchemaArn` ou `SchemaName` doit être fourni.
- `Schemald$ SchemaName` : nom du schéma. `SchemaArn` ou `SchemaName` doit être fourni.
- `SchemaVersionNumber` – Un objet [SchemaVersionNumber](#).

Numéro de version requis pour le pointage de contrôle. `VersionNumber` ou `Compatibility` doit être fourni.

- `Compatibility` – Chaîne UTF-8 (valeurs valides : NONE | DISABLED | BACKWARD | BACKWARD_ALL | FORWARD | FORWARD_ALL | FULL | FULL_ALL).

Nouveau paramètre de compatibilité pour le schéma.

- `Description` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Nouvelle description du schéma.

Réponse

- `SchemaArn` – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'Amazon Resource Name (ARN) du filtre.

- `SchemaName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du schéma.

- `RegistryName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre contenant le schéma.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ConcurrentModificationException`
- `InternalServiceException`

CheckSchemaVersionValidity action (Python : `check_schema_version_validity`)

Valide le schéma fourni. Cet appel n'a pas d'effets secondaires, il effectue simplement une validation en utilisant le schéma fourni à l'aide de `DataFormat`. Comme il ne prend pas de nom de jeu de schéma, aucune vérification de compatibilité n'est effectuée.

Demande

- `DataFormat` – Obligatoire : Chaîne UTF-8 (valeurs valides : `AVRO` | `JSON` | `PROTOBUF`).

Format de données de la définition de schéma. À l'heure actuelle, `AVRO`, `JSON` et `PROTOBUF` sont pris en charge.

- **SchemaDefinition** – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 170 000 octets, correspondant au [Custom string pattern #13](#).

Définition du schéma qui doit être validé.

Réponse

- **Valid** – Booléen.

Renvoie true, si le schéma est valide et false sinon.

- **Error** – Chaîne UTF-8, d'une longueur comprise entre 1 et 5 000 octets.

Message d'erreur d'échec de validation.

Erreurs

- **InvalidInputException**
- **AccessDeniedException**
- **InternalServiceException**

UpdateRegistry action (Python : update_registry)

Met à jour un registre existant qui est utilisé pour contenir une collection de schémas. Les propriétés mises à jour se rapportent au registre et ne modifient aucun des schémas de celui-ci.

Demande

- **RegistryId** – Obligatoire : un objet [RegistryId](#).

Structure d'encapsulation qui peut contenir le nom et l'Amazon Resource Name (ARN) du registre.

- **Description** – Obligatoire : Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du registre. Si la description n'est pas fournie, ce champ ne sera pas mis à jour.

Réponse

- **RegistryName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre mis à jour.

- **RegistryArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

Amazon Resource Name (ARN) du registre mis à jour.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ConcurrentModificationException`
- `InternalServiceException`

GetSchemaByDefinition action (Python : `get_schema_by_definition`)

Récupère un schéma à l'aide de sa `SchemaDefinition`. La définition du schéma est envoyée au registre de schéma, rendue canonique et hachée. Si le hachage correspond à la portée du `SchemaName` ou de l'ARN (ou du registre par défaut, si aucun n'est fourni), les métadonnées de ce schéma sont retournées. Dans le cas contraire, un 404 ou une `NotFound` erreur est renvoyée. Les versions de schémas dont le statut est `Deleted` ne seront pas incluses dans les résultats.

Demande

- **SchemaId** – Obligatoire : un objet [Schemald](#).

Structure d'encapsulation contenant les champs d'identité de schéma. La structure contient :

- `Schemald$ SchemaArn` : Le nom de ressource Amazon (ARN) du schéma. `SchemaArn` ou `SchemaName` doit être fourni.
- `Schemald$ SchemaName` : nom du schéma. `SchemaArn` ou `SchemaName` doit être fourni.
- **SchemaDefinition** – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 170 000 octets, correspondant au [Custom string pattern #13](#).

Définition du schéma pour lequel les détails du schéma sont requis.

Réponse

- `SchemaVersionId` – Chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

ID de schéma de la version du schéma.

- `SchemaArn` – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'Amazon Resource Name (ARN) du filtre.

- `DataFormat` – Chaîne UTF-8 (valeurs valides : AVRO | JSON | PROTOBUF).

Format de données de la définition de schéma. À l'heure actuelle, AVRO, JSON et PROTOBUF sont pris en charge.

- `Status` – Chaîne UTF-8 (valeurs valides : AVAILABLE | PENDING | FAILURE | DELETING).

Statut de la version du schéma.

- `CreatedTime` – Chaîne UTF-8.

Date et heure de création du schéma.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`

GetRegistry action (Python : `get_registry`)

Décrit en détail le registre spécifié.

Demande

- `RegistryId` – Obligatoire : un objet [RegistryId](#).

Structure d'encapsulation qui peut contenir le nom et l'Amazon Resource Name (ARN) du registre.

Réponse

- **RegistryName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre.

- **RegistryArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'Amazon Resource Name (ARN) du registre.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du registre.

- **Status** – Chaîne UTF-8 (valeurs valides : AVAILABLE | DELETING).

Statut du registre.

- **CreatedTime** – Chaîne UTF-8.

Date et heure de création du registre.

- **UpdatedTime** – Chaîne UTF-8.

Date et heure de mise à jour du registre.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`

PutSchemaVersionMetadata action (Python : put_schema_version_metadata)

Place la paire de valeurs clé de métadonnées pour un ID de version de schéma spécifié. Un maximum de 10 paires de valeurs clé sera autorisé par version de schéma. Ils peuvent être ajoutés au moyen d'un ou de plusieurs appels.

Demande

- SchemaId – Un objet [Schemald](#).

ID unique du schéma.

- SchemaVersionNumber – Un objet [SchemaVersionNumber](#).

Numéro de version du schéma.

- SchemaVersionId – Chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

ID de version unique de la version du schéma.

- MetadataKeyValue – Obligatoire : un objet [MetadataKeyValuePair](#).

Valeur correspondant à une clé de métadonnées.

Réponse

- SchemaArn – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

Amazon Resource Name (ARN) du schéma.

- SchemaName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du schéma.

- RegistryName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre.

- LatestVersion – Booléen.

Dernière version du schéma.

- `VersionNumber` – Nombre (long), compris entre 1 et 100 000.

Numéro de version du schéma.

- `SchemaVersionId` – Chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

ID de version unique de la version du schéma.

- `MetadataKey` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #14](#).

Clé de métadonnées.

- `MetadataValue` – Chaîne UTF-8, d'une longueur comprise entre 1 et 256 octets, correspondant au [Custom string pattern #14](#).

Valeur de la clé de métadonnées.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `AlreadyExistsException`
- `EntityNotFoundException`
- `ResourceNumberLimitExceededException`

QuerySchemaVersionMetadata action (Python : `query_schema_version_metadata`)

Requêtes pour les informations de métadonnées de version du schéma.

Demande

- `SchemaId` – Un objet [SchemaId](#).

Structure d'encapsulation qui peut contenir le nom et l'Amazon Resource Name (ARN) du schéma.

- `SchemaVersionNumber` – Un objet [SchemaVersionNumber](#).

Numéro de version du schéma.

- `SchemaVersionId` – Chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

ID de version unique de la version du schéma.

- `MetadataList` – Un tableau d'objets [MetadataKeyValuePair](#).

Rechercher des paires clé-valeur pour les métadonnées, si elles ne sont pas fournies, toutes les informations de métadonnées seront récupérées.

- `MaxResults` – Nombre (entier), compris entre 1 et 50.

Nombre maximum de résultats requis par page. Si la valeur n'est pas fournie, elle par défaut sera de 25 par page.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'un appel de continuation.

Réponse

- `MetadataInfoMap` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #14](#).

Chaque valeur est un objet [MetadataInfo](#).

Carte d'une clé de métadonnées et des valeurs associées.

- `SchemaVersionId` – Chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

ID de version unique de la version du schéma.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation pour la pagination de la liste des jetons renvoyés, renvoyé si le segment actuel de la liste n'est pas le dernier.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`

RemoveSchemaVersionMetadata action (Python : `remove_schema_version_metadata`)

Supprime une paire de valeurs clé des métadonnées de version de schéma pour l'ID de version de schéma spécifié.

Demande

- `SchemaId` – Un objet [SchemaId](#).

Structure d'encapsulation qui peut contenir le nom et l'Amazon Resource Name (ARN) du schéma.

- `SchemaVersionNumber` – Un objet [SchemaVersionNumber](#).

Numéro de version du schéma.

- `SchemaVersionId` – Chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

ID de version unique de la version du schéma.

- `MetadataKeyVal` – Obligatoire : un objet [MetadataKeyValuePair](#).

Valeur de la clé de métadonnées.

Réponse

- `SchemaArn` – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'Amazon Resource Name (ARN) du filtre.

- `SchemaName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du schéma.

- `RegistryName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre.

- `LatestVersion` – Booléen.

Dernière version du schéma.

- `VersionNumber` – Nombre (long), compris entre 1 et 100 000.

Numéro de version du schéma.

- `SchemaVersionId` – Chaîne UTF-8, d'une longueur exacte de 36 octets, correspondant au [Custom string pattern #44](#).

ID de version pour la version du schéma.

- `MetadataKey` – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #14](#).

Clé de métadonnées.

- `MetadataValue` – Chaîne UTF-8, d'une longueur comprise entre 1 et 256 octets, correspondant au [Custom string pattern #14](#).

Valeur de la clé de métadonnées.

Erreurs

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`

DeleteRegistry action (Python : `supprimer_registre`)

Supprimer l'intégralité du registre, y compris le schéma et toutes ses versions. Pour obtenir le statut de l'opération de suppression, vous pouvez appeler l'API `GetRegistry` après l'appel asynchrone. La suppression d'un registre désactivera toutes les opérations en ligne du registre, telles que `leUpdateRegistry`, `CreateSchemaUpdateSchema`, et `RegisterSchemaVersion` APIs.

Demande

- **RegistryId** – Obligatoire : un objet [RegistryId](#).

Structure d'encapsulation qui peut contenir le nom et l'Amazon Resource Name (ARN) du registre.

Réponse

- **RegistryName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du registre en cours de suppression.

- **RegistryArn** – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

Amazon Resource Name (ARN) du registre en cours de suppression.

- **Status** – Chaîne UTF-8 (valeurs valides : AVAILABLE | DELETING).

Statut du registre. La réussite de l'opération retournera le statut DeletIng.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `AccessDeniedException`
- `ConcurrentModificationException`

DeleteSchema action (Python : supprimer_schéma)

Supprime l'ensemble de schémas, y compris le jeu de schémas et toutes ses versions. Pour obtenir le statut de l'opération de suppression, vous pouvez appeler l'API GetSchema après l'appel asynchrone. La suppression d'un registre désactivera toutes les opérations en ligne pour le schéma, telles que leGetSchemaByDefinition, et RegisterSchemaVersion APIs.

Demande

- **SchemaId** – Obligatoire : un objet [Schemald](#).

Structure d'encapsulation qui peut contenir le nom et l'Amazon Resource Name (ARN) du schéma.

Réponse

- SchemaArn – Chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

Amazon Resource Name (ARN) du schéma en cours de suppression.

- SchemaName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #45](#).

Nom du schéma en cours de suppression.

- Status – Chaîne UTF-8 (valeurs valides : AVAILABLE | PENDING | DELETING).

Statut du schéma.

Erreurs

- InvalidInputException
- EntityNotFoundException
- AccessDeniedException
- ConcurrentModificationException

DeleteSchemaVersions action (Python : delete_schema_versions)

Supprimez des versions du schéma spécifié. Un numéro ou une plage de versions peut être fourni. Si le mode de compatibilité interdit la suppression d'une version nécessaire, telle que BACKWARDS_FULL (DESCENDANT_TOUT), une erreur est renvoyée. En appelant l'API GetSchemaVersions après cet appel, vous obtiendrez la liste de l'état des versions supprimées.

Lorsque la plage de numéros de version contient une version comportant un point de contrôle, l'API renvoie un conflit 409 et ne procède pas à la suppression. Vous devez d'abord supprimer le point de contrôle à l'aide de l'API DeleteSchemaCheckpoint avant d'utiliser cette API.

Vous ne pouvez pas utiliser l'API DeleteSchemaVersions pour supprimer la première version de schéma dans le jeu de schémas. La première version de schéma ne peut être

supprimée que par l'appel à l'API `DeleteSchema`. Cette opération supprimera également les `SchemaVersionMetadata` attachées aux versions du schéma. Les suppressions définitives seront appliquées sur la base de données.

Si le mode de compatibilité interdit la suppression d'une version nécessaire, telle que `BACKWARDS_FULL` (`DESCENDANT_TOUT`), une erreur est renvoyée.

Demande

- `SchemaId` – Obligatoire : un objet [SchemaId](#).

Structure d'encapsulation qui peut contenir le nom et l'Amazon Resource Name (ARN) du schéma.

- `Versions` – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 100 000 octets, correspondant au [Custom string pattern #15](#).

Une plage de versions peut être fournie au format suivant :

- un numéro de version unique, 5
- une plage, 5-8 : supprime les versions 5, 6, 7, 8

Réponse

- `SchemaVersionErrors` – Un tableau d'objets [SchemaVersionErrorItem](#).

Une liste d'objets `SchemaVersionErrorItem`, chacun contenant une version d'erreur et de schéma.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `AccessDeniedException`
- `ConcurrentModificationException`

Flux de travail

L'API Workflows décrit les types de données et l'API liés à la création, à la mise à jour ou à l'affichage des flux de travail dans AWS Glue. L'historique d'exécution des tâches est accessible pendant 90 jours pour votre flux de travail et l'exécution des tâches.

Types de données

- [JobNodeDetails structure](#)
- [CrawlerNodeDetails structure](#)
- [TriggerNodeDetails structure](#)
- [Structure Crawl](#)
- [Structure de nœud](#)
- [Structure Edge](#)
- [Structure de flux de travail](#)
- [WorkflowGraph structure](#)
- [WorkflowRun structure](#)
- [WorkflowRunStatistics structure](#)
- [StartingEventBatchCondition structure](#)
- [Structure du plan](#)
- [BlueprintDetails structure](#)
- [LastActiveDefinition structure](#)
- [BlueprintRun structure](#)

JobNodeDetails structure

Détails d'un nœud de tâches présent dans le flux de travail.

Champs

- JobRuns – Un tableau d'objets [JobRun](#).

Informations relatives aux exécutions de tâches représentées par le nœud de tâches.

CrawlerNodeDetails structure

Détails d'un nœud d'crawler présent dans le flux de travail.

Champs

- `Crawls` – Un tableau d'objets [Crawl](#).

Liste de crawlers représentés par le nœud de crawler.

TriggerNodeDetails structure

Détails d'un nœud Trigger présent dans le flux de travail.

Champs

- `Trigger` – Un objet [Déclencheur](#).

Informations relatives au déclencheur représenté par le nœud de déclencheur.

Structure Crawl

Détails d'un crawler dans le flux de travail.

Champs

- `State` – Chaîne UTF-8 (valeurs valides : `RUNNING` | `CANCELLING` | `CANCELLED` | `SUCCEEDED` | `FAILED` | `ERROR`).

État de l'crawler.

- `StartedOn` – Horodatage.

Date et heure auxquelles le crawler a démarré.

- `CompletedOn` – Horodatage.

Date et heure auxquelles l'analyse a terminé.

- `ErrorMessage` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Message d'erreur associé au crawler

- **LogGroup** – Chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets, correspondant au [Log group string pattern](#).

Groupe de journaux associés au crawler.

- **LogStream** – Chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets, correspondant au [Log-stream string pattern](#).

Flux de journaux associé au crawler.

Structure de nœud

Un nœud représente un AWS Glue composant (déclencheur, robot ou tâche) sur un graphe de flux de travail.

Champs

- **Type** – Chaîne UTF-8 (valeurs valides : CRAWLER | JOB | TRIGGER).

Type de AWS Glue composant représenté par le nœud.

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du AWS Glue composant représenté par le nœud.

- **UniqueId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID unique affecté au nœud au sein du flux de travail.

- **TriggerDetails** – Un objet [TriggerNodeDetails](#).

Détails du déclencheur lorsque le nœud représente un déclencheur.

- **JobDetails** – Un objet [JobNodeDetails](#).

Détails de la tâche lorsque le nœud représente une tâche.

- **CrawlerDetails** – Un objet [CrawlerNodeDetails](#).

Détails de l'crawler lorsque le nœud représente un crawler.

Structure Edge

Un arête représente une connexion dirigée entre deux AWS Glue composants qui font partie du flux de travail auquel appartient l'arête.

Champs

- **SourceId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaîne unique du nœud au sein du flux de travail où démarre la périphérie.

- **DestinationId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaîne unique du nœud au sein du flux de travail où la périphérie se termine.

Structure de flux de travail

Un flux de travail est un ensemble de plusieurs AWS Glue tâches dépendantes et de robots d'exploration exécutés pour effectuer une tâche ETL complexe. Un flux de travail gère l'exécution et le suivi de tous ses jobs et crawlers.

Champs

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail.

- **Description** – Chaîne UTF-8.

Description du flux de travail.

- **DefaultRunProperties** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8.

Collection de propriétés à utiliser dans le cadre de chaque exécution du flux de travail. Les propriétés d'exécution sont mises à la disposition de chaque tâche du flux de travail. Une tâche peut modifier les propriétés des tâches suivants dans le flux de travail.

- `CreatedOn` – Horodatage.

Date et heure auxquelles le flux de travail a été créé.

- `LastModifiedOn` – Horodatage.

Date et heure auxquelles le flux de travail a été modifié pour la dernière fois.

- `LastRun` – Un objet [WorkflowRun](#).

Informations relatives à la dernière exécution du flux de travail.

- `Graph` – Un objet [WorkflowGraph](#).

Le graphique représente tous les AWS Glue composants appartenant au flux de travail sous forme de nœuds et les connexions dirigées entre eux sous forme d'arêtes.

- `CreationStatus` – Chaîne UTF-8 (valeurs valides : `CREATING` | `CREATED` | `CREATION_FAILED`).

État de création du flux de travail.

- `MaxConcurrentRuns` – Nombre (entier).

Vous pouvez utiliser ce paramètre pour empêcher plusieurs mises à jour indésirables des données, pour contrôler les coûts ou, dans certains cas, pour empêcher le dépassement du nombre maximal d'exécutions simultanées de l'un des travaux de composant. Si vous laissez ce paramètre vide, le nombre d'exécutions de flux de travail simultanées est illimité.

- `BlueprintDetails` – Un objet [BlueprintDetails](#).

Cette structure indique les détails du plan à partir duquel ce flux de travail particulier est créé.

WorkflowGraph structure

Un graphique de flux de travail représente le flux de travail complet contenant tous les composants AWS Glue présents dans le flux de travail et toutes les connexions dirigées entre eux.

Champs

- Nodes – Un tableau d'objets [Nœud](#).

Une liste des AWS Glue composants appartenant au flux de travail représentés sous forme de nœuds.

- Edges – Un tableau d'objets [Edge](#).

Liste de toutes les connexions dirigées entre les nœuds appartenant au flux de travail.

WorkflowRun structure

Une exécution de flux de travail est une exécution de flux de travail qui fournit toutes les informations d'exécution.

Champs

- Name – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail qui a été exécuté.

- WorkflowRunId – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de cette exécution de flux de travail.

- PreviousRunId – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de la précédente exécution de flux de travail.

- WorkflowRunProperties – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8.

Propriétés d'exécution de flux de travail qui ont été définies au cours de l'exécution.

- StartedOn – Horodatage.

Date et heure auxquelles l'exécution de flux de travail a démarré.

- `CompletedOn` – Horodatage.

Date et heure auxquelles l'exécution de flux de travail a s'est terminée.

- `Status` – Chaîne UTF-8 (valeurs valides : `RUNNING` | `COMPLETED` | `STOPPING` | `STOPPED` | `ERROR`).

État de l'exécution de flux de travail.

- `ErrorMessage` – Chaîne UTF-8.

Ce message d'erreur décrit toute erreur qui peut s'être produite lors du démarrage de l'exécution du flux de travail. Actuellement, le seul message d'erreur est « `Concurrent runs exceeded for workflow: foo` » (Exécutions simultanées dépassées pour le flux de travail : `foo`).

- `Statistics` – Un objet [WorkflowRunStatistics](#).

Statistiques de l'exécution.

- `Graph` – Un objet [WorkflowGraph](#).

Le graphique représente tous les AWS Glue composants appartenant au flux de travail sous forme de nœuds et les connexions dirigées entre eux sous forme d'arêtes.

- `StartingEventBatchCondition` – Un objet [StartingEventBatchCondition](#).

Condition de lot qui a démarré l'exécution du flux de travail.

WorkflowRunStatistics structure

Le flux de travail exécutent des statistiques et fournit des statistiques sur l'exécution du flux de travail.

Champs

- `TotalActions` – Nombre (entier).

Nombre total d'actions dans l'exécution du flux de travail.

- `TimeoutActions` – Nombre (entier).

Nombre total d'actions qui ont expiré.

- `FailedActions` – Nombre (entier).

Nombre total d'actions qui ont échoué.

- `StoppedActions` – Nombre (entier).

Nombre total d'actions qui sont arrêtées.

- `SucceededActions` – Nombre (entier).

Nombre total d'actions qui ont réussi.

- `RunningActions` – Nombre (entier).

Nombre total d'actions en cours d'exécution.

- `ErroredActions` – Nombre (entier).

Indique le nombre d'exécutions de tâches dans l'état `ERROR` dans l'exécution du flux de travail.

- `WaitingActions` – Nombre (entier).

Indique le nombre d'exécutions de tâches en état `WAITING` dans l'exécution du flux de travail.

StartingEventBatchCondition structure

Condition de lot qui a démarré l'exécution du flux de travail. Soit le nombre d'événements de la taille du lot est arrivé, auquel cas le `BatchSize` membre est différent de zéro, soit la fenêtre du lot a expiré, auquel cas le `BatchWindow` membre est différent de zéro.

Champs

- `BatchSize` – Nombre (entier).

Nombre d'événements dans le lot.

- `BatchWindow` – Nombre (entier).

Durée de la fenêtre de traitement par lots en secondes.

Structure du plan

Détails d'un plan.

Champs

- **Name** – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Nom du plan.

- **Description** – chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets.

Description du plan.

- **CreatedOn** – Horodatage.

Date et heure d'enregistrement du plan.

- **LastModifiedOn** – Horodatage.

Date et heure auxquelles le plan a été modifié pour la dernière fois.

- **ParameterSpec** – chaîne UTF-8, d'une longueur comprise entre 1 et 131 072 octets.

Chaîne JSON qui indique la liste des spécifications de paramètres pour le plan.

- **BlueprintLocation** – Chaîne UTF-8.

Spécifie le chemin dans Amazon S3 où le plan est publié.

- **BlueprintServiceLocation** – Chaîne UTF-8.

Spécifie un chemin dans Amazon S3 où le plan est copié lorsque vous appelez `CreateBlueprint/UpdateBlueprint` pour enregistrer le plan dans AWS Glue.

- **Status** – Chaîne UTF-8 (valeurs valides : `CREATING` | `ACTIVE` | `UPDATING` | `FAILED`).

Statut de l'enregistrement du plan.

- **Création** : l'enregistrement du plan est en cours.
- **Actif** : le plan a été enregistré avec succès.
- **Mise à jour** : une mise à jour de l'enregistrement du plan est en cours.
- **Échec** : l'enregistrement du plan a échoué.
- **ErrorMessage** – Chaîne UTF-8.

Message d'erreur.

- **LastActiveDefinition** – Un objet [LastActiveDefinition](#).

Lorsqu'il existe plusieurs versions d'un plan et que la dernière version contient des erreurs, cet attribut indique la dernière définition de plan réussie qui est disponible avec le service.

BlueprintDetails structure

Détails d'un plan.

Champs

- `BlueprintName` – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Nom du plan.

- `RunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution de ce plan.

LastActiveDefinition structure

Lorsqu'il existe plusieurs versions d'un plan et que la dernière version contient des erreurs, cet attribut indique la dernière définition de plan réussie qui est disponible avec le service.

Champs

- `Description` – chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets.

Description du plan.

- `LastModifiedOn` – Horodatage.

Date et heure auxquelles le plan a été modifié pour la dernière fois.

- `ParameterSpec` – chaîne UTF-8, d'une longueur comprise entre 1 et 131 072 octets.

Chaîne JSON spécifiant les paramètres du plan.

- `BlueprintLocation` – Chaîne UTF-8.

Spécifie un chemin dans Amazon S3 où le plan est publié par le AWS Glue développeur.

- `BlueprintServiceLocation` – Chaîne UTF-8.

Spécifie un chemin dans Amazon S3 où le plan est copié lorsque vous créez ou mettez à jour ce dernier.

BlueprintRun structure

Détails d'une exécution de plan.

Champs

- **BlueprintName** – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Nom du plan.

- **RunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution de cette exécution de plan.

- **WorkflowName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom d'un flux de travail créé à la suite d'une exécution réussie du plan. Si une exécution de plan comporte une erreur, aucun flux de travail ne sera créé.

- **State** – Chaîne UTF-8 (valeurs valides : RUNNING | SUCCEEDED | FAILED | ROLLING_BACK).

État de l'exécution du plan. Les valeurs possibles sont :

- En cours d'exécution : l'exécution du plan est en cours.
- Réussi : l'exécution du plan s'est terminée.
- Échec : l'exécution du plan a échoué et la restauration est terminée.
- Annuler : l'exécution du plan a échoué et la restauration est en cours.
- **StartedOn** – Horodatage.

Date et heure auxquelles l'exécution du plan a démarré.

- **CompletedOn** – Horodatage.

Date et heure auxquelles le modèle a été exécuté.

- **ErrorMessage** – Chaîne UTF-8.

Indique les erreurs détectées lors de l'exécution du plan.

- `RollbackErrorMessage` – Chaîne UTF-8.

S'il y a des erreurs lors de la création des entités d'un flux de travail, nous essayons de restaurer les entités créées jusqu'à ce point et de les supprimer. Cet attribut indique les erreurs rencontrées lors de la tentative de suppression des entités créées.

- `Parameters` – chaîne UTF-8, d'une longueur comprise entre 1 et 131 072 octets.

Paramètres du plan sous la forme d'une chaîne. Vous devrez fournir une valeur pour chaque clé requise à partir de la spécification de paramètre définie dans `Blueprint$ParameterSpec`.

- `RoleArn` – Chaîne UTF-8, d'une longueur comprise entre 1 et 1024 octets, correspondant au [Custom string pattern #30](#).

ARN du rôle. Ce rôle sera assumé par le AWS Glue service et sera utilisé pour créer le flux de travail et les autres entités d'un flux de travail.

Opérations

- [CreateWorkflow action \(Python : `create\_workflow`\)](#)
- [UpdateWorkflow action \(Python : `update\_workflow`\)](#)
- [DeleteWorkflow action \(Python : `delete\_workflow`\)](#)
- [GetWorkflow action \(Python : `get\_workflow`\)](#)
- [ListWorkflows action \(Python : `list\_workflows`\)](#)
- [BatchGetWorkflows action \(Python : `batch\_get\_workflows`\)](#)
- [GetWorkflowRun action \(Python : `get\_workflow\_run`\)](#)
- [GetWorkflowRuns action \(Python : `get\_workflow\_runs`\)](#)
- [GetWorkflowRunProperties action \(Python : `get\_workflow\_run\_properties`\)](#)
- [PutWorkflowRunProperties action \(Python : `put\_workflow\_run\_properties`\)](#)
- [CreateBlueprint action \(Python : `créer\_blueprint`\)](#)
- [UpdateBlueprint action \(Python : `update\_blueprint`\)](#)
- [DeleteBlueprint action \(Python : `delete\_blueprint`\)](#)
- [ListBlueprints action \(Python : `list\_blueprints`\)](#)
- [BatchGetBlueprints action \(Python : `batch\_get\_blueprints`\)](#)

- [StartBlueprintRun action \(Python : start_blueprint_run\)](#)
- [GetBlueprintRun action \(Python : get_blueprint_run\)](#)
- [GetBlueprintRuns action \(Python : get_blueprint_runs\)](#)
- [StartWorkflowRun action \(Python : start_workflow_run\)](#)
- [StopWorkflowRun action \(Python : stop_workflow_run\)](#)
- [ResumeWorkflowRun action \(Python : resume_workflow_run\)](#)

CreateWorkflow action (Python : create_workflow)

Crée un nouveau flux de travail.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom à affecter au flux de travail. Il doit être unique au sein de votre compte.

- **Description**— Chaîne UTF-8 d'une longueur maximale de 120 000 octets.

Description du flux de travail.

- **DefaultRunProperties** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8.

Collection de propriétés à utiliser dans le cadre de chaque exécution du flux de travail.

Les propriétés d'exécution peuvent être enregistrées. Ne transmettez pas de secrets en texte brut en tant que propriétés. Récupérez les secrets d'une AWS Glue connexion, d'un Gestionnaire de AWS Secrets ou d'un autre mécanisme de gestion des secrets si vous avez l'intention de les utiliser dans le cadre de l'exécution du flux de travail.

- **Tags** – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Balises à utiliser avec ce flux de travail.

- `MaxConcurrentRuns` – Nombre (entier).

Vous pouvez utiliser ce paramètre pour empêcher plusieurs mises à jour indésirables des données, pour contrôler les coûts ou, dans certains cas, pour empêcher le dépassement du nombre maximal d'exécutions simultanées de l'un des travaux de composant. Si vous laissez ce paramètre vide, le nombre d'exécutions de flux de travail simultanées est illimité.

Réponse

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail qui a été fourni dans le cadre de la requête.

Erreurs

- `AlreadyExistsException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`

UpdateWorkflow action (Python : `update_workflow`)

Met à jour un flux de travail existant.

Demande

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail à mettre à jour.

- `Description`— Chaîne UTF-8 d'une longueur maximale de 120 000 octets.

Description du flux de travail.

- `DefaultRunProperties` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8.

Collection de propriétés à utiliser dans le cadre de chaque exécution du flux de travail.

Les propriétés d'exécution peuvent être enregistrées. Ne transmettez pas de secrets en texte brut en tant que propriétés. Récupérez les secrets d'une AWS Glue connexion, d'un Gestionnaire de AWS Secrets ou d'un autre mécanisme de gestion des secrets si vous avez l'intention de les utiliser dans le cadre de l'exécution du flux de travail.

- `MaxConcurrentRuns` – Nombre (entier).

Vous pouvez utiliser ce paramètre pour empêcher plusieurs mises à jour indésirables des données, pour contrôler les coûts ou, dans certains cas, pour empêcher le dépassement du nombre maximal d'exécutions simultanées de l'un des travaux de composant. Si vous laissez ce paramètre vide, le nombre d'exécutions de flux de travail simultanées est illimité.

Réponse

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail qui a été spécifié dans l'entrée.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

DeleteWorkflow action (Python : delete_workflow)

Supprime un flux de travail.

Demande

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail à supprimer.

Réponse

- Name – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail spécifié dans l'entrée.

Erreurs

- InvalidInputException
- InternalServiceException
- OperationTimeoutException
- ConcurrentModificationException

GetWorkflow action (Python : get_workflow)

Récupère les métadonnées de ressource pour un flux de travail.

Demande

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail à récupérer.

- IncludeGraph – Booléen.

Indique si un graphique doit être inclus lors du renvoi de métadonnées de ressource de flux de travail.

Réponse

- Workflow – Un objet [Flux de travail](#).

Métadonnées de ressource du flux de travail.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

ListWorkflows action (Python : `list_workflows`)

Affiche les noms des flux de travail créés dans le compte.

Demande

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'une requête de continuation.

- `MaxResults`— Nombre (entier), pas moins de 1 ou plus de 25.

La taille maximale d'une liste à renvoyer.

Réponse

- `Workflows` – tableau de chaînes UTF-8, avec 1 chaîne minimum et 25 chaînes maximum.

Liste des noms des flux de travail dans le compte.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, si tous les noms de flux de travail n'ont pas été retournés.

Erreurs

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

BatchGetWorkflows action (Python : `batch_get_workflows`)

Retourne la liste des métadonnées de ressource pour une liste donnée de noms de flux de travail. Après avoir appelé l'opération `ListWorkflows`, vous pouvez appeler cette opération pour accéder aux données sur lesquelles des autorisations vous ont été octroyées. Cette opération prend en charge toutes les autorisations IAM, y compris les conditions d'autorisation qui utilisent des balises.

Demande

- **Names** – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 25 chaînes maximum.

Liste des noms de flux de travail, qui peuvent être les noms renvoyés à partir de l'opération `ListWorkflows`.

- **IncludeGraph** – Booléen.

Indique si un graphique doit être inclus lors du renvoi de métadonnées de ressource de flux de travail.

Réponse

- **Workflows** – tableau d'objets [Flux de travail](#), avec 1 structure minimum et 25 structures maximum.

Liste de métadonnées de ressource de flux de travail.

- **MissingWorkflows** – tableau de chaînes UTF-8, avec 1 chaîne minimum et 25 chaînes maximum.

Liste des noms de flux de travail non trouvés.

Erreurs

- `InternalServiceException`
- `OperationTimeoutException`

- `InvalidInputException`

GetWorkflowRun action (Python : `get_workflow_run`)

Extrait les métadonnées pour une exécution de flux de travail donnée. L'historique d'exécution des tâches est accessible pendant 90 jours pour votre flux de travail et l'exécution des tâches.

Demande

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail en cours d'exécution.

- `RunId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de l'exécution de flux de travail.

- `IncludeGraph` – Booléen.

Indique si le graphique de flux de travail doit être inclus en réponse ou non.

Réponse

- `Run` – Un objet [WorkflowRun](#).

Métadonnées d'exécution de flux de travail demandées.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

GetWorkflowRuns action (Python : `get_workflow_runs`)

Extrait les métadonnées de toutes les exécutions d'un flux de travail donné.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail dont les métadonnées des exécutions doivent être renvoyées.

- **IncludeGraph** – Booléen.

Indique si le graphique de flux de travail doit être inclus en réponse ou non.

- **NextToken** – Chaîne UTF-8.

Taille maximale de la réponse.

- **MaxResults** – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal d'exécutions de flux de travail à inclure dans la réponse.

Réponse

- **Runs** – tableau d'objets [WorkflowRun](#), avec 1 structure minimum et 1 000 structures maximum.

Liste d'objets des métadonnées d'exécution de flux de travail.

- **NextToken** – Chaîne UTF-8.

Jeton de continuation, si toutes les exécutions de tâche demandées ne sont pas renvoyées.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

GetWorkflowRunProperties action (Python : `get_workflow_run_properties`)

Extrait les propriétés d'exécution de flux de travail qui ont été définies au cours de l'exécution.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail qui a été exécuté.

- **RunId** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de l'exécution de flux de travail dont les propriétés d'exécution doivent être renvoyées.

Réponse

- **RunProperties** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8.

Propriétés d'exécution de flux de travail qui ont été définies au cours de l'exécution spécifiée.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

PutWorkflowRunProperties action (Python : `put_workflow_run_properties`)

Place les propriétés d'exécution de flux de travail spécifiées pour l'exécution de flux de travail donnée. Si une propriété existe déjà pour l'exécution spécifiée, elle remplace la valeur et ajoute la propriété aux propriétés existantes.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail qui a été exécuté.

- **RunId** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de l'exécution de flux de travail pour laquelle les propriétés d'exécution doivent être mises à jour.

- **RunProperties** – obligatoire : tableau de mappage de paires clé-valeur.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8.

Propriétés à placer pour l'exécution spécifiée.

Les propriétés d'exécution peuvent être enregistrées. Ne transmettez pas de secrets en texte brut en tant que propriétés. Récupérez les secrets d'une AWS Glue connexion, d'un Gestionnaire de AWS Secrets ou d'un autre mécanisme de gestion des secrets si vous avez l'intention de les utiliser dans le cadre de l'exécution du flux de travail.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `AlreadyExistsException`
- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`

CreateBlueprint action (Python : créer_blueprint)

Enregistre un plan avec AWS Glue.

Demande

- Name – obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Nom du plan.

- Description – chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets.

Description du plan.

- BlueprintLocation – obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 8 192 octets, correspondant au [Custom string pattern #32](#).

Spécifie un chemin dans Amazon S3 où le plan est publié.

- Tags – tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Balises à appliquer à ce plan.

Réponse

- Name – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Renvoie le nom du plan qui a été enregistré.

Erreurs

- AlreadyExistsException
- InvalidInputException
- OperationTimeoutException
- InternalServiceException

- `ResourceNumberLimitExceededException`

UpdateBlueprint action (Python : `update_blueprint`)

Met à jour un plan enregistré.

Demande

- `Name` – obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Nom du plan.

- `Description` – chaîne UTF-8, d'une longueur comprise entre 1 et 512 octets.

Description du plan.

- `BlueprintLocation` – obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 8 192 octets, correspondant au [Custom string pattern #32](#).

Spécifie un chemin dans Amazon S3 où le plan est publié.

Réponse

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Renvoie le nom du plan qui a été mis à jour.

Erreurs

- `EntityNotFoundException`
- `ConcurrentModificationException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `IllegalBlueprintStateException`

DeleteBlueprint action (Python : delete_blueprint)

Supprime un plan existant.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du plan à supprimer.

Réponse

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Renvoie le nom du plan qui a été supprimé.

Erreurs

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

ListBlueprints action (Python : list_blueprints)

Répertorie tous les noms de plan d'un compte.

Demande

- **NextToken** – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'une requête de continuation.

- **MaxResults**— Nombre (entier), pas moins de 1 ou plus de 25.

La taille maximale d'une liste à renvoyer.

- **Tags** – tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Filtre la liste en fonction d'une balise de AWS ressource.

Réponse

- `Blueprints` – Tableau de chaînes UTF-8.

Liste des noms des plans dans le compte.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, si tous les noms de plan n'ont pas été renvoyés.

Erreurs

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

BatchGetBlueprints action (Python : `batch_get_blueprints`)

Extrait des informations sur une liste de plans.

Demande

- `Names` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 25 chaînes maximum.

Une liste de noms de plan.

- `IncludeBlueprint` – Booléen.

Indique si le plan doit être inclus dans la réponse ou non.

- `IncludeParameterSpec` – Booléen.

Spécifie s'il faut ou non inclure les paramètres, sous forme de chaîne JSON, pour le plan dans la réponse.

Réponse

- `Blueprints` – Un tableau d'objets [Plan](#).

Renvoie la liste des plans sous forme d'objet `Blueprints`.

- `MissingBlueprints` – Tableau de chaînes UTF-8.

Renvoie une liste de `BlueprintNames` qui ont été introuvables.

Erreurs

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

StartBlueprintRun action (Python : `start_blueprint_run`)

Démarre une nouvelle exécution du plan spécifié.

Demande

- `BlueprintName` – obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Nom du plan.

- `Parameters` – chaîne UTF-8, d'une longueur comprise entre 1 et 131 072 octets.

Spécifie les paramètres en tant qu'objet `BlueprintParameters`.

- `RoleArn` – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 1024 octets, correspondant au [Custom string pattern #30](#).

Spécifie le rôle IAM utilisé pour créer le flux de travail.

Réponse

- `RunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution de cette exécution de plan.

Erreurs

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ResourceNumberLimitExceededException`
- `EntityNotFoundException`
- `IllegalBlueprintStateException`

GetBlueprintRun action (Python : `get_blueprint_run`)

Récupère les détails d'une exécution de plan.

Demande

- `BlueprintName` – obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #31](#).

Nom du plan.

- `RunId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution de l'exécution de plan que vous souhaitez récupérer.

Réponse

- `BlueprintRun` – Un objet [BlueprintRun](#).

Renvoie un objet `BlueprintRun`.

Erreurs

- `EntityNotFoundException`
- `InternalServiceException`

- `OperationTimeoutException`

GetBlueprintRuns action (Python : `get_blueprint_runs`)

Récupère les détails des exécutions de plan pour un plan spécifié.

Demande

- `BlueprintName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du plan.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'une requête de continuation.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

La taille maximale d'une liste à renvoyer.

Réponse

- `BlueprintRuns` – Un tableau d'objets [BlueprintRun](#).

Envoie la liste des objets `BlueprintRun`.

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, si toutes les exécutions de plan ne sont pas renvoyées.

Erreurs

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

StartWorkflowRun action (Python : start_workflow_run)

Démarre une nouvelle exécution du flux de travail spécifié.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail à démarrer.

- **RunProperties** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne UTF-8.

Les propriétés d'exécution de flux de travail pour la nouvelle exécution de flux de travail.

Les propriétés d'exécution peuvent être enregistrées. Ne transmettez pas de secrets en texte brut en tant que propriétés. Récupérez les secrets d'une AWS Glue connexion, d'un Gestionnaire de AWS Secrets ou d'un autre mécanisme de gestion des secrets si vous avez l'intention de les utiliser dans le cadre de l'exécution du flux de travail.

Réponse

- **RunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID pour la nouvelle exécution.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

- `ConcurrentRunsExceededException`

StopWorkflowRun action (Python : `stop_workflow_run`)

Arrête l'exécution du cycle de flux de travail spécifié.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail à arrêter.

- **RunId** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de du cycle de flux de travail à arrêter.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `IllegalWorkflowStateException`

ResumeWorkflowRun action (Python : `resume_workflow_run`)

Redémarre les nœuds sélectionnés d'une précédente exécution de flux de travail partiellement terminée et reprend l'exécution de flux de travail. Les nœuds sélectionnés et tous les nœuds en aval des nœuds sélectionnés sont exécutés.

Demande

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du flux de travail à reprendre.

- RunId – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de l'exécution du flux de travail à reprendre.

- NodeIds – obligatoire : tableau de chaînes UTF-8.

Liste IDs des nœuds que vous souhaitez redémarrer. Les nœuds qui doivent être redémarrés doivent avoir une tentative d'exécution dans l'exécution d'origine.

Réponse

- RunId – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nouvel ID attribué à l'exécution de flux de travail reprise. Chaque résumé d'exécution de flux de travail aura un nouvel ID d'exécution.

- NodeIds – Tableau de chaînes UTF-8.

Liste des nœuds IDs qui ont été réellement redémarrés.

Erreurs

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentRunsExceededException`
- `IllegalWorkflowStateException`

Profils d'utilisation

L'API des profils d'utilisation décrit les types de données et l'API liés à la création, à la mise à jour ou à l'affichage des profils d'utilisation dans AWS Glue.

Types de données

- [ProfileConfiguration structure](#)
- [ConfigurationObject structure](#)
- [UsageProfileDefinition structure](#)

ProfileConfiguration structure

Spécifie les valeurs de tâche et de session qu'un administrateur configure dans un profil AWS Glue d'utilisation.

Champs

- **SessionConfiguration** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est un objet [ConfigurationObject](#).

Une carte clé-valeur des paramètres de configuration pour AWS Glue les sessions.

- **JobConfiguration** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est un objet [ConfigurationObject](#).

Une carte clé-valeur des paramètres de configuration pour AWS Glue les tâches.

ConfigurationObject structure

Spécifie les valeurs définies par un administrateur pour chaque paramètre de tâche ou de session configuré dans un profil AWS Glue d'utilisation.

Champs

- **DefaultValue** – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #35](#).

Une valeur par défaut pour le paramètre.

- **AllowedValues** – Tableau de chaînes UTF-8.

Liste des valeurs autorisées pour le paramètre.

- **MinValue** – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #35](#).

Valeur minimale autorisée pour le paramètre.

- **MaxValue** – chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets, correspondant au [Custom string pattern #35](#).

Valeur maximale autorisée pour le paramètre.

UsageProfileDefinition structure

Décrit un profil AWS Glue d'utilisation.

Champs

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du profil d'utilisation.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du profil d'utilisation.

- **CreatedOn** – Horodatage.

Date et heure de création du profil d'utilisation.

- **LastModifiedOn** – Horodatage.

Date et heure de dernière modification du profil d'utilisation.

Opérations

- [CreateUsageProfile action \(Python : create_usage_profile\)](#)
- [GetUsageProfile action \(Python : get_usage_profile\)](#)
- [UpdateUsageProfile action \(Python : update_usage_profile\)](#)
- [DeleteUsageProfile action \(Python : delete_usage_profile\)](#)
- [ListUsageProfiles action \(Python : list_usage_profiles\)](#)

CreateUsageProfile action (Python : create_usage_profile)

Crée un profil AWS Glue d'utilisation.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du profil d'utilisation.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du profil d'utilisation.

- **Configuration** – Obligatoire : un objet [ProfileConfiguration](#).

ProfileConfigurationObjet spécifiant les valeurs de tâche et de session pour le profil.

- **Tags** – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Liste des balises appliquées au profil d'utilisation.

Réponse

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du profil d'utilisation créé.

Erreurs

- `InvalidInputException`
- `InternalServiceException`
- `AlreadyExistsException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `OperationNotSupportedException`

GetUsageProfile action (Python : `get_usage_profile`)

Récupère les informations relatives au profil AWS Glue d'utilisation spécifié.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du profil d'utilisation à récupérer.

Réponse

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du profil d'utilisation.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du profil d'utilisation.

- **Configuration** – Un objet [ProfileConfiguration](#).

`ProfileConfiguration`Objet spécifiant les valeurs de tâche et de session pour le profil.

- **CreatedOn** – Horodatage.

Date et heure de création du profil d'utilisation.

- LastModifiedOn – Horodatage.

Date et heure de dernière modification du profil d'utilisation.

Erreurs

- InvalidInputException
- InternalServiceException
- EntityNotFoundException
- OperationTimeoutException
- OperationNotSupportedException

UpdateUsageProfile action (Python : update_usage_profile)

Mettez à jour un profil AWS Glue d'utilisation.

Demande

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du profil d'utilisation.

- Description – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description du profil d'utilisation.

- Configuration – Obligatoire : un objet [ProfileConfiguration](#).

ProfileConfigurationObjet spécifiant les valeurs de tâche et de session pour le profil.

Réponse

- Name – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du profil d'utilisation qui a été mis à jour.

Erreurs

- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `OperationNotSupportedException`
- `ConcurrentModificationException`

DeleteUsageProfile action (Python : `delete_usage_profile`)

Supprime le profil d'utilisation AWS Glue spécifié.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du profil d'utilisation à supprimer.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `OperationNotSupportedException`

ListUsageProfiles action (Python : `list_usage_profiles`)

Répertoriez tous les profils AWS Glue d'utilisation.

Demande

- `NextToken` – Chaîne UTF-8, d'une longueur maximale de 400 000 octets.

Jeton de continuation, inclus s'il s'agit d'un appel de continuation.

- `MaxResults`— Nombre (entier), pas moins de 1 ou plus de 200.

Le nombre maximum de profils d'utilisation à renvoyer dans une seule réponse.

Réponse

- `Profiles` – Un tableau d'objets [UsageProfileDefinition](#).

Liste des objets du profil d'utilisation (`UsageProfileDefinition`).

- `NextToken` – Chaîne UTF-8, d'une longueur maximale de 400 000 octets.

Jeton de continuation, présent si le segment de liste actuel n'est pas le dernier.

Erreurs

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `OperationNotSupportedException`

API de Machine Learning

L'API Machine learning décrit les types de données du machine learning et inclut l'API de création, suppression ou mise à jour d'une transformation, ou de démarrage de l'exécution d'une tâche de machine learning.

Types de données

- [TransformParameters structure](#)
- [EvaluationMetrics structure](#)
- [MLTransform structure](#)

- [FindMatchesParameters structure](#)
- [FindMatchesMetrics structure](#)
- [ConfusionMatrix structure](#)
- [GlueTable structure](#)
- [TaskRun structure](#)
- [TransformFilterCriteria structure](#)
- [TransformSortCriteria structure](#)
- [TaskRunFilterCriteria structure](#)
- [TaskRunSortCriteria structure](#)
- [TaskRunProperties structure](#)
- [FindMatchesTaskRunProperties structure](#)
- [ImportLabelsTaskRunProperties structure](#)
- [ExportLabelsTaskRunProperties structure](#)
- [LabelingSetGenerationTaskRunProperties structure](#)
- [SchemaColumn structure](#)
- [TransformEncryption structure](#)
- [MLUserDataEncryption structure](#)
- [ColumnImportance structure](#)

TransformParameters structure

Paramètres propres à l'algorithme associés à la transformation Machine Learning.

Champs

- `TransformType` – Obligatoire : Chaîne UTF-8 (valeurs valides : `FIND_MATCHES`).

Type de transformation du Machine Learning.

Pour de plus amples informations sur les types de transformation du Machine Learning, veuillez consulter [Création de transformations du Machine Learning](#).

- `FindMatchesParameters` – Un objet [FindMatchesParameters](#).

Paramètres de l'algorithme de recherche de correspondances.

EvaluationMetrics structure

Les métriques d'évaluation fournissent une estimation de la qualité de votre transformation du Machine Learning.

Champs

- `TransformType` – Obligatoire : Chaîne UTF-8 (valeurs valides : `FIND_MATCHES`).

Type de transformation du Machine Learning.

- `FindMatchesMetrics` – Un objet [FindMatchesMetrics](#).

Métriques d'évaluation de l'algorithme de recherche de correspondances.

MLTransform structure

Structure d'une transformation du Machine Learning.

Champs

- `TransformId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de transformation unique généré pour la transformation du Machine Learning. L'ID est garanti être unique et ne pas changer.

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom défini par l'utilisateur de la transformation Machine Learning. Les noms ne sont pas garantis être uniques et peuvent être modifiés à tout moment.

- `Description` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Longue description définie par l'utilisateur de la transformation Machine Learning. Les descriptions ne sont pas garanties être uniques et peuvent être modifiées à tout moment.

- `Status` – Chaîne UTF-8 (valeurs valides : `NOT_READY` | `READY` | `DELETING`).

Statut actuel de la transformation du Machine Learning.

- `CreatedOn` – Horodatage.

Horodatage. Heure et date auxquelles la transformation du Machine Learning a été créée.

- `LastModifiedOn` – Horodatage.

Horodatage. Dernier moment auquel cette transformation du Machine Learning a été modifiée.

- `InputRecordTables` – Un tableau d'objets [GlueTable](#), 10 structures au maximum.

Liste des définitions de AWS Glue table utilisées par la transformation.

- `Parameters` – Un objet [TransformParameters](#).

Un objet `TransformParameters`. Vous pouvez utiliser des paramètres pour ajuster (personnaliser) le comportement de la transformation du Machine Learning : à cette fin, spécifiez les données apprises du Machine Learning, ainsi que vos préférences quant aux différents compromis à faire (valeur versus rappel, ou précision versus coût, par exemple).

- `EvaluationMetrics` – Un objet [EvaluationMetrics](#).

Un objet `EvaluationMetrics`. Les métriques d'évaluation fournissent une estimation de la qualité de votre transformation du Machine Learning.

- `LabelCount` – Nombre (entier).

Identifiant de comptage pour les fichiers d'étiquetage générés par AWS Glue cette transformation. Au fur et à mesure que vous créez une transformation de meilleure qualité, vous pouvez, de manière itérative, télécharger, étiqueter et charger le fichier d'étiquetage.

- `Schema` – Un tableau d'objets [SchemaColumn](#), 100 structures au maximum.

Carte de paires clé-valeur correspondant aux colonnes et aux types de données sur lesquels la transformation peut s'exécuter. Comporte une limite supérieure de 100 colonnes.

- `Role` – Chaîne UTF-8.

Nom ou Amazon Resource Name (ARN) du rôle IAM avec les autorisations requises. Les autorisations requises incluent à la fois les autorisations de rôle de AWS Glue service sur les AWS Glue ressources et les autorisations Amazon S3 requises par la transformation.

- Ce rôle nécessite des autorisations AWS Glue de rôle de service pour autoriser l'accès aux ressources dans AWS Glue. Veuillez consulter la rubrique [Attacher une politique aux utilisateurs IAM accédant à AWS Glue](#).

- Ce rôle a besoin d'une autorisation pour vos sources, vos cibles, votre répertoire temporaire et vos scripts Amazon Simple Storage Service (Amazon S3), ainsi que pour les bibliothèques utilisées par l'exécution de la tâche dans le cadre de cette transformation.
- `GlueVersion` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

Cette valeur détermine la version compatible avec laquelle AWS Glue cette transformation de machine learning est compatible. Glue 1.0 est recommandé pour la plupart des clients. Si la valeur n'est pas définie, la compatibilité Glue par défaut est Glue 0.9. Pour plus d'informations, veuillez consulter la rubrique [Versions AWS Glue](#) dans le guide du développeur.

- `MaxCapacity` – Nombre (double).

Nombre d'unités de traitement de AWS Glue données (DPUs) allouées aux exécutions de tâches pour cette transformation. Vous pouvez allouer de 2 à 100 DPUs ; la valeur par défaut est 10. Un DPU est une mesure relative de la puissance de traitement composée de 4 vCPU de capacité CPU de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

`MaxCapacity` est une option mutuellement exclusive avec `NumberOfWorkers` et `WorkerType`.

- Si `NumberOfWorkers` ou `WorkerType` est défini, `MaxCapacity` peut pas être défini.
- Si `MaxCapacity` est défini, ni `NumberOfWorkers` ni `WorkerType` ne peuvent être définis.
- Si `WorkerType` est défini, `NumberOfWorkers` est obligatoire (et inversement).
- `MaxCapacity` et `NumberOfWorkers` doivent être au moins égal à 1.

Lorsque le champ `WorkerType` est défini sur une valeur autre que `Standard`, le champ `MaxCapacity` est défini automatiquement et passe en lecture seule.

- `WorkerType` – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type d'exécuteur prédéfini qui est alloué lorsqu'une tâche de cette transformation s'exécute. Accepte la valeur `Standard`, `G.1X` ou `G.2X`.

- Pour le type de travail `Standard`, chaque travail fournit 4 vCPU, 16 Go de mémoire et 50 Go de disque, ainsi que 2 exécuteurs par travail.
- Pour le type de travail `G.1X`, chaque travail fournit 4 vCPU, 16 Go de mémoire et 64 Go de disque, ainsi que 1 exécuteur par travail.

- Pour le type de travail G.2X, chaque travail fournit 8 vCPU, 32 Go de mémoire et 128 Go de disque, ainsi que 1 exécuteur par travail.

MaxCapacity est une option mutuellement exclusive avec NumberOfWorkers et WorkerType.

- Si NumberOfWorkers ou WorkerType est défini, ne MaxCapacity peut pas être défini.
- Si MaxCapacity est défini, ni NumberOfWorkers ni WorkerType ne peuvent être définis.
- Si WorkerType est défini, NumberOfWorkers est obligatoire (et inversement).
- MaxCapacity et NumberOfWorkers doivent être au moins égal à 1.
- NumberOfWorkers – Nombre (entier).

Nombre d'exécuteurs d'un workerType défini qui sont alloués lorsqu'une tâche de la transformation s'exécute.

Si WorkerType est défini, NumberOfWorkers est obligatoire (et inversement).

- Timeout – Nombre (entier), au moins égal à 1.

Délai d'expiration en minutes de la transformation Machine Learning.

- MaxRetries – Nombre (entier).

Nombre maximal de tentatives autorisées après l'échec d'une exécution MLTaskRun de la transformation Machine Learning.

- TransformEncryption – Un objet [TransformEncryption](#).

Les encryption-at-rest paramètres de la transformation qui s'appliquent à l'accès aux données utilisateur. Les transformations de machine learning peuvent accéder aux données utilisateur chiffrées dans Amazon S3 à l'aide de KMS.

FindMatchesParameters structure

Paramètres de configuration de la transformation de la recherche des correspondances.

Champs

- PrimaryKeyColumnName – Chaîne UTF-8, d'une longueur comprise entre 1 et 1024 octets, correspondant au [Single-line string pattern](#).

Nom d'une colonne qui identifie de façon unique les lignes de la table source. Utilisé pour vous aider à identifier les enregistrements correspondants.

- `PrecisionRecallTradeoff` – Nombre (double), au plus égal à 1,0.

Valeur sélectionnée lors du paramétrage de votre transformation pour un équilibre entre la précision et le rappel. Une valeur de 0,5 signifie aucune préférence ; une valeur de 1.0 signifie un écart uniquement pour la précision, et une valeur de 0,0 un écart pour le rappel. Comme il s'agit d'un compromis, le choix de valeurs proches de 1.0 signifie un rappel très faible et le choix de valeurs proches de 0.0 une très faible précision.

La précision métrique indique la fréquence à laquelle votre modèle est correct lorsqu'il prédit une correspondance.

La métrique de rappel indique que pour une correspondance réelle, la fréquence à laquelle votre modèle prédit la correspondance.

- `AccuracyCostTradeoff` – Nombre (double), au plus égal à 1,0.

Valeur sélectionnée lors du paramétrage de votre transformation pour un équilibre entre la précision et le coût. Une valeur de 0,5 signifie que le système équilibre les préoccupations de précision et de coût. Une valeur de 1.0 signifie un biais uniquement pour la précision, ce qui entraîne généralement un coût plus élevé, et parfois beaucoup plus élevé. Une valeur de 0,0 signifie un biais uniquement pour le coût, ce qui se traduit par une transformation `FindMatches` moins précise, et parfois une précision inacceptable.

La précision mesure la façon dont la transformation trouve les vrais positifs et les vrais négatifs. L'augmentation de la précision nécessite plus de ressources machine et des coûts supérieurs. Mais elle entraîne également une augmentation du rappel.

Le coût mesure le nombre de ressources de calcul, et donc le montant, consommées pour exécuter la transformation.

- `EnforceProvidedLabels` – Booléen.

La valeur à activer ou désactiver pour forcer la sortie afin qu'elle corresponde aux étiquettes fournies par les utilisateurs. Si la valeur est `True`, la transformation `find matches` oblige la sortie à correspondre aux étiquettes fournies. Les résultats remplacent les résultats de combinaison normaux. Si la valeur est `False`, la transformation `find matches` ne garantit pas que toutes les étiquettes fournies sont respectées, et les résultats s'appuient sur le modèle formé.

Notez que la définition de cette valeur sur true peut augmenter la durée d'exécution de la combinaison.

FindMatchesMetrics structure

Métriques d'évaluation de l'algorithme de recherche de correspondances. La qualité de votre transformation Machine Learning est mesurée en obtenant que votre transformation prédise certaines correspondances et en comparant les résultats pour connaître les correspondances du même jeu de données. Les métriques de qualité sont basées sur un sous-ensemble de vos données, afin qu'ils ne soient pas précis.

Champs

- `AreaUnderPRCurve` – Nombre (double), au plus égal à 1,0.

L'aire sous la precision/recall courbe (AUPRC) est un nombre unique qui mesure la qualité globale de la transformation, indépendamment du choix fait entre précision et rappel. Les valeurs élevées indiquent que vous avez un compromis précision vs. rappel plus attrayant.

Pour en savoir plus, consultez [Précision et rappel](#) dans Wikipédia.

- `Precision` – Nombre (double), au plus égal à 1,0.

La précision métrique indique à quelle fréquence votre transformation est correcte lorsqu'elle prédit une correspondance. Plus précisément, elle évalue la fréquence à laquelle la transformation trouve de vrais positifs à partir du total de vrais positifs possible.

Pour en savoir plus, consultez [Précision et rappel](#) dans Wikipédia.

- `Recall` – Nombre (double), au plus égal à 1,0.

La sensibilité métrique indique pour une correspondance réelle, la fréquence à laquelle votre transformation prédit la correspondance. Plus précisément, elle évalue la fréquence à laquelle la transformation trouve de vrais positifs à partir du total des enregistrements de la source de données.

Pour en savoir plus, consultez [Précision et rappel](#) dans Wikipédia.

- `F1` – Nombre (double), au plus égal à 1,0.

La métrique F1 maximale indique la précision de la transformation entre 0 et 1, où 1 est la meilleure précision.

Pour plus d'informations, consultez la page Wikipedia relative au [score F1](#).

- `ConfusionMatrix` – Un objet [ConfusionMatrix](#).

La matrice de confusion vous explique ce que votre transformation prédit avec précision et quels types d'erreurs elle effectue.

Pour plus d'informations, consultez [Matrice de confusion](#) dans Wikipédia.

- `ColumnImportances` – Un tableau d'objets [ColumnImportance](#), 100 structures au maximum.

Une liste de structures `ColumnImportance` contenant des métriques d'importance de colonne, triées par ordre d'importance décroissant.

ConfusionMatrix structure

La matrice de confusion vous explique ce que votre transformation prédit avec précision et quels types d'erreurs elle effectue.

Pour plus d'informations, consultez [Matrice de confusion](#) dans Wikipédia.

Champs

- `NumTruePositives` – Nombre (long).

Nombre de correspondances dans les données que la transformation a trouvées correctement, dans la matrice de confusion de votre transformation.

- `NumFalsePositives` – Nombre (long).

Le nombre de non-correspondances dans les données que la transformation a classées de manière incorrecte comme correspondance, dans la matrice de confusion de votre transformation.

- `NumTrueNegatives` – Nombre (long).

Nombre de non-correspondances dans les données que la transformation a rejetées correctement, dans la matrice de confusion de votre transformation.

- `NumFalseNegatives` – Nombre (long).

Nombre de correspondances dans les données que la transformation n'a pas trouvées, dans la matrice de confusion de votre transformation.

GlueTable structure

Base de données et table utilisées pour AWS Glue Data Catalog les données d'entrée ou de sortie.

Champs

- **DatabaseName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données dans le AWS Glue Data Catalog.

- **TableName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la table dans AWS Glue Data Catalog.

- **CatalogId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique pour AWS Glue Data Catalog.

- **ConnectionName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la connexion à AWS Glue Data Catalog.

- **AdditionalOptions** – Tableau de mappage de paires valeur-clé, pas moins de 1 ou plus de 10 paires..

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne Description, d'une longueur ne dépassant pas 2048 octets, correspondant au [URI address multi-line string pattern](#).

Options supplémentaires pour la table. Actuellement, deux clés sont prises en charge :

- **pushDownPredicate** : pour filtrer les partitions sans avoir à répertorier ni lire tous les fichiers de votre jeu de données.

- `catalogPartitionPredicate` : pour utiliser le nettoyage de partition côté serveur à l'aide des index de partition du AWS Glue Data Catalog.

TaskRun structure

Paramètres d'échantillonnage qui sont associés à la transformation du Machine Learning.

Champs

- `TransformId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation.

- `TaskRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la tâche exécutée.

- `Status` – Chaîne UTF-8 (valeurs valides : `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

Statut actuel de la tâche demandée.

- `LogGroupName` – Chaîne UTF-8.

Nom du groupe de journaux pour une journalisation sécurisée, associée à la tâche exécutée.

- `Properties` – Un objet [TaskRunProperties](#).

Spécifie les propriétés de configuration associées à la tâche exécutée.

- `ErrorString` – Chaîne UTF-8.

Liste des chaînes d'erreur associées à la tâche exécutée.

- `StartedOn` – Horodatage.

Date et heure auxquelles la tâche exécutée a démarré.

- `LastModifiedOn` – Horodatage.

Dernière date de modification de la tâche exécutée demandée.

- `CompletedOn` – Horodatage.

Heure à laquelle l'exécution de la tâche demandée s'est terminée.

- `ExecutionTime` – Nombre (entier).

Durée (en secondes) pendant laquelle la tâche exécutée a consommé des ressources.

TransformFilterCriteria structure

Critères utilisés pour filtrer les transformations du Machine Learning.

Champs

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de transformation unique qui est utilisé pour filtrer les transformations du Machine Learning.

- `TransformType` – Chaîne UTF-8 (valeurs valides : `FIND_MATCHES`).

Type de transformation du Machine Learning utilisé pour filtrer les transformations du Machine Learning.

- `Status` – Chaîne UTF-8 (valeurs valides : `NOT_READY` | `READY` | `DELETING`).

Filtre la liste des transformations du Machine Learning sur le dernier état connu des transformations (pour indiquer si une transformation peut être utilisée ou non). L'un des états « `NOT_READY` », « `READY` » ou « `DELETING` ».

- `GlueVersion` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

Cette valeur détermine la version compatible avec laquelle AWS Glue cette transformation de machine learning est compatible. Glue 1.0 est recommandé pour la plupart des clients. Si la valeur n'est pas définie, la compatibilité Glue par défaut est Glue 0.9. Pour plus d'informations, veuillez consulter la rubrique [Versions AWS Glue](#) dans le guide du développeur.

- `CreatedBefore` – Horodatage.

Heure et date avant lesquelles les transformations ont été créées.

- `CreatedAfter` – Horodatage.

Heure et date après lesquelles les transformations ont été créées.

- `LastModifiedBefore` – Horodatage.

Filtre sur les dernières transformations modifiées avant cette date.

- `LastModifiedAfter` – Horodatage.

Filtre sur les dernières transformations modifiées après cette date.

- `Schema` – Un tableau d'objets [SchemaColumn](#), 100 structures au maximum.

Filtre sur les ensembles de données avec un schéma spécifique. L'objet `Map<Column, Type>` est un tableau de paires clé-valeur qui représente le schéma que cette transformation accepte, où `Column` est le nom d'une colonne, et `Type` le type de données, comme nombre entier ou chaîne. Comporte une limite supérieure de 100 colonnes.

TransformSortCriteria structure

Critères de tri associés à la transformation du Machine Learning.

Champs

- `Column` – Obligatoire : Chaîne UTF-8 (valeurs valides : `NAME` | `TRANSFORM_TYPE` | `STATUS` | `CREATED` | `LAST_MODIFIED`).

La colonne doit être utilisée dans les critères de tri associés à la transformation du Machine Learning.

- `SortDirection` – Obligatoire : Chaîne UTF-8 (valeurs valides : `DESCENDING` | `ASCENDING`).

La direction de tri doit être utilisée dans les critères de tri associés à la transformation du Machine Learning.

TaskRunFilterCriteria structure

Critères utilisés pour filtrer les exécutions de tâche pour la transformation du Machine Learning.

Champs

- `TaskRunType` – Chaîne UTF-8 (valeurs valides : `EVALUATION` | `LABELING_SET_GENERATION` | `IMPORT_LABELS` | `EXPORT_LABELS` | `FIND_MATCHES`).

Type de tâche exécutée.

- **Status** – Chaîne UTF-8 (valeurs valides : RUNNING | FINISHED | FAILED | PENDING_EXECUTION | TIMED_OUT | CANCELING | CANCELED | RECEIVED_BY_TASKRUNNER).

Statut actuel de la tâche exécutée.

- **StartedBefore** – Horodatage.

Filtre sur les exécutions de tâche démarrées avant cette date.

- **StartedAfter** – Horodatage.

Filtre sur les exécutions de tâche démarrées après cette date.

TaskRunSortCriteria structure

Critères de tri utilisés pour trier la liste des exécutions de tâche pour la transformation du Machine Learning.

Champs

- **Column** – Obligatoire : Chaîne UTF-8 (valeurs valides : TASK_RUN_TYPE | STATUS | STARTED).

La colonne doit être utilisée pour trier la liste des exécutions de tâche pour la transformation du Machine Learning.

- **SortDirection** – Obligatoire : Chaîne UTF-8 (valeurs valides : DESCENDING | ASCENDING).

La direction de tri doit être utilisée pour trier la liste des exécutions de tâche pour la transformation du Machine Learning.

TaskRunProperties structure

Propriétés de configuration pour la tâche exécutée.

Champs

- **TaskType** – Chaîne UTF-8 (valeurs valides : EVALUATION | LABELING_SET_GENERATION | IMPORT_LABELS | EXPORT_LABELS | FIND_MATCHES).

Type de tâche exécutée.

- **ImportLabelsTaskRunProperties** – Un objet [ImportLabelsTaskRunProperties](#).

Propriétés de configuration d'une exécution de tâche d'importation des étiquettes.

- `ExportLabelsTaskRunProperties` – Un objet [ExportLabelsTaskRunProperties](#).

Propriétés de configuration d'une exécution de tâche d'exportation des étiquettes.

- `LabelingSetGenerationTaskRunProperties` – Un objet [LabelingSetGenerationTaskRunProperties](#).

Propriétés de configuration pour une exécution de tâches de génération d'ensemble d'étiquetage.

- `FindMatchesTaskRunProperties` – Un objet [FindMatchesTaskRunProperties](#).

Propriétés de configuration pour une exécution de tâche de recherche de correspondances.

FindMatchesTaskRunProperties structure

Spécifie les propriétés de configuration d'une exécution de tâche de recherche de correspondances.

Champs

- `JobId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de tâche d'une exécution de tâche de recherche de correspondances.

- `JobName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom attribué à la tâche pour l'exécution de tâche de recherche de correspondances.

- `JobRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution de tâche d'une exécution de tâche de recherche de correspondances.

ImportLabelsTaskRunProperties structure

Spécifie les propriétés de configuration d'une exécution de tâche de l'importation des étiquettes.

Champs

- `InputS3Path` – Chaîne UTF-8.

Chemin Amazon Simple Storage Service (Amazon S3) à partir d'où vous allez importer les étiquettes.

- `Replace` – Booléen.

Indique si vous souhaitez remplacer vos étiquettes existantes.

ExportLabelsTaskRunProperties structure

Spécifie les propriétés de configuration d'une exécution de tâche d'exportation des étiquettes.

Champs

- `OutputS3Path` – Chaîne UTF-8.

Chemin Amazon Simple Storage Service (Amazon S3) où vous allez exporter les étiquettes.

LabelingSetGenerationTaskRunProperties structure

Spécifie les propriétés de configuration pour une exécution de tâches de génération d'ensemble d'étiquetage.

Champs

- `OutputS3Path` – Chaîne UTF-8.

Chemin Amazon Simple Storage Service (Amazon S3) où vous allez générer l'ensemble d'étiquetage.

SchemaColumn structure

Paire clé-valeur qui représente une colonne et type de données sur lesquels cette transformation peut être exécuté. Le paramètre `Schema` de la `MLTransform` peut contenir jusqu'à 100 de ces structures.

Champs

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 1024 octets, correspondant au [Single-line string pattern](#).

Le nom de la colonne.

- `DataType` – Chaîne UTF-8, d'une longueur maximale de 131 072 octets, correspondant au [Single-line string pattern](#).

Type de données de la colonne.

TransformEncryption structure

Les encryption-at-rest paramètres de la transformation qui s'appliquent à l'accès aux données utilisateur. Les transformations de machine learning peuvent accéder aux données utilisateur chiffrées dans Amazon S3 à l'aide de KMS.

De plus, les étiquettes importées et les transformations formées peuvent désormais être chiffrées à l'aide d'une clé KMS fournie par le client.

Champs

- `MLUserDataEncryption` – Un objet [MLUserDataEncryption](#).

Objet `MLUserDataEncryption` contenant le mode de chiffrement et l'ID de la clé KMS fournie par le client.

- `TaskRunSecurityConfigurationName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité.

MLUserDataEncryption structure

Les encryption-at-rest paramètres de la transformation qui s'appliquent à l'accès aux données utilisateur.

Champs

- `MLUserDataEncryptionMode` – Obligatoire : Chaîne UTF-8 (valeurs valides : `DISABLED` | `SSE-KMS="SSEKMS"`).

Mode de chiffrement appliqué aux données utilisateur. Les valeurs valides sont :

- `DISABLED` : le chiffrement est désactivé

- SSEKMS : utilisation du chiffrement côté serveur avec AWS Key Management Service (SSE-KMS) pour les données utilisateur stockées dans Amazon S3.
- KmsKeyId – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de la clé KMS fournie par le client.

ColumnImportance structure

Structure contenant le nom de colonne et son score d'importance de colonne.

L'importance des colonnes vous aide à comprendre comment elles contribuent à votre modèle, en identifiant les colonnes de vos enregistrements qui sont plus importantes que les autres.

Champs

- ColumnName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom d'une colonne.

- Importance – Nombre (double), au plus égal à 1,0.

Score d'importance de colonne pour la colonne, sous la forme d'une décimale.

Opérations

- [Créer une MLTransform action \(Python : create_ml_transform\)](#)
- [MLTransform Action de mise à jour \(Python : update_ml_transform\)](#)
- [MLTransform Action de suppression \(Python : delete_ml_transform\)](#)
- [Obtenir une MLTransform action \(Python : get_ml_transform\)](#)
- [Obtenir une MLTransforms action \(Python : get_ml_transform\)](#)
- [MLTransforms Action de liste \(Python : list_ml_transform\)](#)
- [Lancer MLEvaluation TaskRun l'action \(Python : start_ml_evaluation_task_run\)](#)
- [Lancer MLLabeling SetGenerationTaskRun l'action \(Python : start_ml_labeling_set_generation_task_run\)](#)
- [Action Get MLTask Run \(Python : get_ml_task_run\)](#)

- [Action Get MLTask Runs \(Python : `get\_ml\_task\_runs`\)](#)
- [Annuler l'action MLTask Exécuter \(Python : `cancel\_ml\_task\_run`\)](#)
- [StartExportLabelsTaskRun action \(Python : `start\_export\_labels\_task\_run`\)](#)
- [StartImportLabelsTaskRun action \(Python : `start\_import\_labels\_task\_run`\)](#)

Créer une MLTransform action (Python : `create_ml_transform`)

Crée une transformation basée sur le AWS Glue machine learning. Cette opération crée la transformation et tous les paramètres nécessaires pour la former.

Appelez cette opération comme première étape du processus d'utilisation d'une transformation du Machine Learning (comme la transformation FindMatches) pour la déduplication des données. Vous pouvez fournir une Description facultative, en plus des paramètres que vous souhaitez utiliser pour votre algorithme.

Vous devez également définir certains paramètres pour les tâches exécutées en votre nom AWS Glue dans le cadre de l'apprentissage à partir de vos données et de la création d'une transformation d'apprentissage automatique de haute qualité. Ces paramètres incluent Role et, le cas échéant, AllocatedCapacity, Timeout et MaxRetries. Pour en savoir plus, consultez [Jobs](#) (Tâches).

Demande

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom unique que vous attribuez à la transformation lorsque vous la créez.

- Description – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la transformation du Machine Learning qui est définie. La valeur par défaut est une chaîne vide.

- InputRecordTables – Obligatoire : Un tableau d'objets [GlueTable](#), 10 structures au maximum.

Liste des définitions de AWS Glue table utilisées par la transformation.

- Parameters – Obligatoire : un objet [TransformParameters](#).

Paramètres algorithmiques spécifiques au type de transformation utilisé. Dépendant de façon conditionnelle du type de transformation.

- `Role` – Obligatoire : chaîne UTF-8.

Nom ou Amazon Resource Name (ARN) du rôle IAM avec les autorisations requises. Les autorisations requises incluent à la fois les autorisations de rôle de AWS Glue service sur les AWS Glue ressources et les autorisations Amazon S3 requises par la transformation.

- Ce rôle nécessite des autorisations AWS Glue de rôle de service pour autoriser l'accès aux ressources dans AWS Glue. Veuillez consulter la rubrique [Attacher une politique aux utilisateurs IAM accédant à AWS Glue](#).
- Ce rôle a besoin d'une autorisation pour vos sources, vos cibles, votre répertoire temporaire et vos scripts Amazon Simple Storage Service (Amazon S3), ainsi que pour les bibliothèques utilisées par l'exécution de la tâche dans le cadre de cette transformation.
- `GlueVersion` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

Cette valeur détermine la version compatible avec laquelle AWS Glue cette transformation de machine learning est compatible. Glue 1.0 est recommandé pour la plupart des clients. Si la valeur n'est pas définie, la compatibilité Glue par défaut est Glue 0.9. Pour plus d'informations, veuillez consulter la rubrique [Versions AWS Glue](#) dans le guide du développeur.

- `MaxCapacity` – Nombre (double).

Nombre d'unités de traitement de AWS Glue données (DPUs) allouées aux exécutions de tâches pour cette transformation. Vous pouvez allouer de 2 à 100 DPUs ; la valeur par défaut est 10. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

`MaxCapacity` est une option mutuellement exclusive avec `NumberOfWorkers` et `WorkerType`.

- Si `NumberOfWorkers` ou `WorkerType` est défini, ne `MaxCapacity` peut pas être défini.
- Si `MaxCapacity` est défini, ni `NumberOfWorkers` ni `WorkerType` ne peuvent être définis.
- Si `WorkerType` est défini, `NumberOfWorkers` est obligatoire (et inversement).
- `MaxCapacity` et `NumberOfWorkers` doivent être au moins égal à 1.

Lorsque le champ `WorkerType` est défini sur une valeur autre que `Standard`, le champ `MaxCapacity` est défini automatiquement et passe en lecture seule.

Lorsque le champ `WorkerType` est défini sur une valeur autre que `Standard`, le champ

~~`MaxCapacity` est défini automatiquement et passe en lecture seule.~~

- `WorkerType` – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type de travail prédéfini qui est alloué lorsqu'une tâche est exécutée. Accepte la valeur `Standard`, `G.1X` ou `G.2X`.

- Pour le type de travail `Standard`, chaque travail fournit 4 vCPU, 16 Go de mémoire et 50 Go de disque, ainsi que 2 exécuteurs par travail.
- Pour le type de travail `G.1X`, chaque travail fournit 4 vCPU, 16 Go de mémoire et 64 Go de disque, ainsi que 1 exécuteur par travail.
- Pour le type de travail `G.2X`, chaque travail fournit 8 vCPU, 32 Go de mémoire et 128 Go de disque, ainsi que 1 exécuteur par travail.

`MaxCapacity` est une option mutuellement exclusive avec `NumberOfWorkers` et `WorkerType`.

- Si `NumberOfWorkers` ou `WorkerType` est défini, `MaxCapacity` peut pas être défini.
- Si `MaxCapacity` est défini, ni `NumberOfWorkers` ni `WorkerType` ne peuvent être définis.
- Si `WorkerType` est défini, `NumberOfWorkers` est obligatoire (et inversement).
- `MaxCapacity` et `NumberOfWorkers` doivent être au moins égal à 1.
- `NumberOfWorkers` – Nombre (entier).

Nombre de travaux d'un `workerType` défini qui sont attribués lorsqu'une tâche est exécutée.

Si `WorkerType` est défini, `NumberOfWorkers` est obligatoire (et inversement).

- `Timeout` – Nombre (entier), au moins égal à 1.

Délai d'expiration de la tâche exécutée pour cette transformation en minutes. Durée maximale pendant laquelle l'exécution d'une tâche pour cette transformation peut utiliser des ressources avant qu'elle ne soit mise hors service et passe à l'état `TIMEOUT`. La valeur par défaut est de 2 880 minutes (48 heures).

- `MaxRetries` – Nombre (entier).

Nombre maximal de nouvelles tentatives d'une tâche de cette transformation après l'échec de l'exécution d'une tâche.

- `Tags` – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Balises à utiliser avec cette transformation de Machine Learning. Vous pouvez utiliser des balises pour limiter l'accès à la transformation de Machine Learning. Pour plus d'informations sur les tags in AWS Glue, voir [AWS Tags in AWS Glue](#) dans le guide du développeur.

- `TransformEncryption` – Un objet [TransformEncryption](#).

Les encryption-at-rest paramètres de la transformation qui s'appliquent à l'accès aux données utilisateur. Les transformations de machine learning peuvent accéder aux données utilisateur chiffrées dans Amazon S3 à l'aide de KMS.

Réponse

- `TransformId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique généré pour la transformation.

Erreurs

- `AlreadyExistsException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `AccessDeniedException`
- `ResourceNumberLimitExceededException`
- `IdempotentParameterMismatchException`

MLTransform Action de mise à jour (Python : `update_ml_transform`)

Met à jour une transformation du Machine Learning existante. Appelez cette opération pour ajuster les paramètres de l'algorithme afin d'obtenir de meilleurs résultats.

Après l'appel de cette opération, vous pouvez appeler l'opération `StartMLEvaluationTaskRun` pour évaluer comment vos nouveaux paramètres ont atteint vos objectifs (par exemple, améliorer la qualité de votre transformation Machine Learning, ou la rendre plus rentable).

Demande

- **TransformId** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique qui a été généré lorsque la transformation a été créée.

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom unique que vous avez donné à la transformation lorsque vous l'avez créée.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la transformation. La valeur par défaut est une chaîne vide.

- **Parameters** – Un objet [TransformParameters](#).

Paramètres de configuration spécifiques au type de transformation (algorithme) utilisé. Dépendant de façon conditionnelle du type de transformation.

- **Role** – Chaîne UTF-8.

Nom ou Amazon Resource Name (ARN) du rôle IAM avec les autorisations requises.

- **GlueVersion** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

Cette valeur détermine la version compatible avec laquelle AWS Glue cette transformation de machine learning est compatible. Glue 1.0 est recommandé pour la plupart des clients. Si la valeur n'est pas définie, la compatibilité Glue par défaut est Glue 0.9. Pour plus d'informations, veuillez consulter la rubrique [Versions AWS Glue](#) dans le guide du développeur.

- **MaxCapacity** – Nombre (double).

Nombre d'unités de traitement de AWS Glue données (DPUs) allouées aux exécutions de tâches pour cette transformation. Vous pouvez allouer de 2 à 100 DPUs ; la valeur par défaut est 10. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

Lorsque le champ `WorkerType` est défini sur une valeur autre que `Standard`, le champ `MaxCapacity` est défini automatiquement et passe en lecture seule.

- **WorkerType** – Chaîne UTF-8 (valeurs valides: Standard="" | G.1X="" | G.2X="" | G.025X="" | G.4X="" | G.8X="" | Z.2X="").

Type de travail prédéfini qui est alloué lorsqu'une tâche est exécutée. Accepte la valeur Standard, G.1X ou G.2X.

- Pour le type de travail Standard, chaque travail fournit 4 vCPU, 16 Go de mémoire et 50 Go de disque, ainsi que 2 exécuteurs par travail.
- Pour le type de travail G.1X, chaque travail fournit 4 vCPU, 16 Go de mémoire et 64 Go de disque, ainsi que 1 exécuteur par travail.
- Pour le type de travail G.2X, chaque travail fournit 8 vCPU, 32 Go de mémoire et 128 Go de disque, ainsi que 1 exécuteur par travail.
- **NumberOfWorkers** – Nombre (entier).

Nombre de travaux d'un workerType défini qui sont attribués lorsqu'une tâche est exécutée.

- **Timeout** – Nombre (entier), au moins égal à 1.

Délai d'attente (en minutes) d'une tâche exécutée pour cette transformation. Durée maximale pendant laquelle l'exécution d'une tâche pour cette transformation peut utiliser des ressources avant qu'elle ne soit mise hors service et passe à l'état TIMEOUT. La valeur par défaut est de 2 880 minutes (48 heures).

- **MaxRetries** – Nombre (entier).

Nombre maximal de nouvelles tentatives d'une tâche de cette transformation après l'échec de l'exécution d'une tâche.

Réponse

- **TransformId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation qui a été mise à jour.

Erreurs

- **EntityNotFoundException**
- **InvalidInputException**

- `OperationTimeoutException`
- `InternalServiceException`
- `AccessDeniedException`

MLTransform Action de suppression (Python : `delete_ml_transform`)

Supprime toute transformation AWS Glue de machine learning. Les transformations Machine Learning sont un type spécial de transformation qui utilisent le Machine Learning pour découvrir les détails de la transformation à exécuter par l'apprentissage à partir d'exemples fournis par les humains. Ces transformations sont ensuite enregistrées par AWS Glue. Si vous n'avez plus besoin d'une transformation, vous pouvez la supprimer en appelant `DeleteMLTransforms`. Cependant, toutes les AWS Glue tâches qui font toujours référence à la transformation supprimée ne seront plus couronnées de succès.

Demande

- `TransformId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation à supprimer.

Réponse

- `TransformId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation qui a été supprimée.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Obtenir une MLTransform action (Python : get_ml_transform)

Récupère un artefact de transformation basé sur le AWS Glue machine learning et toutes les métadonnées correspondantes. Les transformations Machine Learning sont un type spécial de transformation qui utilisent le Machine Learning pour découvrir les détails de la transformation à exécuter par l'apprentissage à partir d'exemples fournis par les humains. Ces transformations sont ensuite enregistrées par AWS Glue. Vous pouvez récupérer leurs métadonnées en appelant `GetMLTransform`.

Demande

- `TransformId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation, générée à l'heure à laquelle la transformation a été créée.

Réponse

- `TransformId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation, générée à l'heure à laquelle la transformation a été créée.

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom unique donné à la transformation lors de sa création.

- `Description` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la transformation.

- `Status` – Chaîne UTF-8 (valeurs valides : `NOT_READY` | `READY` | `DELETING`).

Dernier état connu de la transformation (pour indiquer si elle peut être utilisée ou non). L'un des états « `NOT_READY` », « `READY` » ou « `DELETING` ».

- `CreatedOn` – Horodatage.

Date et heure de création de la transformation.

- `LastModifiedOn` – Horodatage.

Date et heure de la dernière modification de la transformation.

- `InputRecordTables` – Un tableau d'objets [GlueTable](#), 10 structures au maximum.

Liste des définitions de AWS Glue table utilisées par la transformation.

- `Parameters` – Un objet [TransformParameters](#).

Paramètres de configuration spécifiques à l'algorithme utilisé.

- `EvaluationMetrics` – Un objet [EvaluationMetrics](#).

Dernières métriques d'évaluation.

- `LabelCount` – Nombre (entier).

Nombre d'étiquettes disponibles pour cette transformation.

- `Schema` – Un tableau d'objets [SchemaColumn](#), 100 structures au maximum.

Objet `Map<Column, Type>` qui représente le schéma que cette transformation accepte. Comporte une limite supérieure de 100 colonnes.

- `Role` – Chaîne UTF-8.

Nom ou Amazon Resource Name (ARN) du rôle IAM avec les autorisations requises.

- `GlueVersion` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #47](#).

Cette valeur détermine la version compatible avec laquelle AWS Glue cette transformation de machine learning est compatible. Glue 1.0 est recommandé pour la plupart des clients. Si la valeur n'est pas définie, la compatibilité Glue par défaut est Glue 0.9. Pour plus d'informations, veuillez consulter la rubrique [Versions AWS Glue](#) dans le guide du développeur.

- `MaxCapacity` – Nombre (double).

Nombre d'unités de traitement de AWS Glue données (DPUs) allouées aux exécutions de tâches pour cette transformation. Vous pouvez allouer de 2 à 100 DPUs ; la valeur par défaut est 10. Un DPU est une mesure relative de la puissance de traitement composée de 4 V de capacité CPUs de calcul et de 16 Go de mémoire. Pour plus d'informations, consultez la page de tarification [AWS Glue](#).

Lorsque le champ `WorkerType` est défini sur une valeur autre que `Standard`, le champ `MaxCapacity` est défini automatiquement et passe en lecture seule.

- `WorkerType` – Chaîne UTF-8 (valeurs valides: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

Type de travail prédéfini qui est alloué lorsqu'une tâche est exécutée. Accepte la valeur `Standard`, `G.1X` ou `G.2X`.

- Pour le type de travail `Standard`, chaque travail fournit 4 vCPU, 16 Go de mémoire et 50 Go de disque, ainsi que 2 exécuteurs par travail.
- Pour le type de travail `G.1X`, chaque travail fournit 4 vCPU, 16 Go de mémoire et 64 Go de disque, ainsi que 1 exécuteur par travail.
- Pour le type de travail `G.2X`, chaque travail fournit 8 vCPU, 32 Go de mémoire et 128 Go de disque, ainsi que 1 exécuteur par travail.
- `NumberOfWorkers` – Nombre (entier).

Nombre de travaux d'un `workerType` défini qui sont attribués lorsqu'une tâche est exécutée.

- `Timeout` – Nombre (entier), au moins égal à 1.

Délai d'attente (en minutes) d'une tâche exécutée pour cette transformation. Durée maximale pendant laquelle l'exécution d'une tâche pour cette transformation peut utiliser des ressources avant qu'elle ne soit mise hors service et passe à l'état `TIMEOUT`. La valeur par défaut est de 2 880 minutes (48 heures).

- `MaxRetries` – Nombre (entier).

Nombre maximal de nouvelles tentatives d'une tâche de cette transformation après l'échec de l'exécution d'une tâche.

- `TransformEncryption` – Un objet [TransformEncryption](#).

Les encryption-at-rest paramètres de la transformation qui s'appliquent à l'accès aux données utilisateur. Les transformations de machine learning peuvent accéder aux données utilisateur chiffrées dans Amazon S3 à l'aide de KMS.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Obtenir une MLTransforms action (Python : `get_ml_transform`)

Obtient une liste triable et filtrable des transformations d'apprentissage AWS Glue automatique existantes. Les transformations Machine Learning sont un type spécial de transformation qui utilisent le Machine Learning pour découvrir les détails de la transformation à exécuter par l'apprentissage à partir d'exemples fournis par les humains. Ces transformations sont ensuite enregistrées par AWS Glue, et vous pouvez récupérer leurs métadonnées en appelant `GetMLTransforms`.

Demande

- `NextToken` – Chaîne UTF-8.

Jeton de pagination pour décaler les résultats.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats à renvoyer.

- `Filter` – Un objet [TransformFilterCriteria](#).

Critères de transformation du filtre.

- `Sort` – Un objet [TransformSortCriteria](#).

Critères de tri.

Réponse

- `Transforms` – Obligatoire : Un tableau d'objets [MLTransform](#).

Liste de transformations du Machine Learning.

- `NextToken` – Chaîne UTF-8.

Un jeton de pagination, si d'autres résultats sont disponibles.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

MLTransforms Action de liste (Python : list_ml_transform)

Récupère une liste triable et filtrable des transformations de AWS Glue machine learning existantes dans ce AWS compte, ou des ressources avec le tag spécifié. Cette opération accepte le champ Tags facultatif que vous pouvez utiliser comme filtre sur les réponses, afin que les ressources balisées puissent être récupérées en tant que groupe. Si vous choisissez d'utiliser le filtrage des balises, seules les ressources avec les balises sont récupérées.

Demande

- `NextToken` – Chaîne UTF-8.

Jeton de continuation, s'il s'agit d'une requête de continuation.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

La taille maximale d'une liste à renvoyer.

- `Filter` – Un objet [TransformFilterCriteria](#).

Élément `TransformFilterCriteria` utilisé pour filtrer les transformations de Machine Learning.

- `Sort` – Un objet [TransformSortCriteria](#).

Élément `TransformSortCriteria` utilisé pour trier les transformations de Machine Learning.

- `Tags` – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Spécifie de renvoyer uniquement les ressources balisées.

Réponse

- `TransformIds` – Obligatoire : Tableau de chaînes UTF-8.

Identifiants de toutes les transformations de Machine Learning dans le compte, ou les transformations de Machine Learning avec les balises spécifiées.

- `NextToken` – Chaîne UTF-8.

Jeton continuation, si la liste renvoyée ne contient pas la dernière métrique disponible.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Lancer `MLEvaluation TaskRun` l'action (Python : `start_ml_evaluation_task_run`)

Démarre une tâche pour estimer la qualité de la transformation.

Lorsque vous fournissez des ensembles d'étiquettes comme exemples de vérité, l'apprentissage AWS Glue automatique utilise certains de ces exemples pour en tirer des leçons. Le reste des étiquettes est utilisé en tant que test pour estimer la qualité.

Retourne un identifiant unique pour l'exécution. Vous pouvez appeler `GetMLTaskRun` pour obtenir plus d'informations sur les statistiques de `EvaluationTaskRun`.

Demande

- `TransformId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation du Machine Learning.

Réponse

- `TaskRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique associé à cette exécution.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`

- `OperationTimeoutException`
- `InternalServiceException`
- `ConcurrentRunsExceededException`
- `MLTransformNotReadyException`

Lancer `MLLabeling SetGenerationTaskRun` l'action (Python : `start_ml_labeling_set_generation_task_run`)

Démarre le flux de travail de l'apprentissage actif d'apprentissage automatique pour votre transformation de Machine Learning afin d'améliorer la qualité de la transformation en générant des ensembles d'étiquette et en ajoutant des étiquettes.

Quand `StartMLLabelingSetGenerationTaskRun` a pris fin, AWS Glue aura généré un « jeu d'étiquetage » ou un ensemble de questions auxquelles les humains devront répondre.

Dans le cas de la transformation `FindMatches`, ces questions prennent la forme : « Quel est le bon moyen de regrouper conjointement ces lignes en groupes composés d'enregistrements correspondants ? »

Une fois que le processus d'étiquetage est terminé, vous pouvez charger vos étiquettes avec un appel à `StartImportLabelsTaskRun`. Une fois `StartImportLabelsTaskRun` terminé, toutes les futures exécutions de la transformation du Machine Learning utiliseront les nouvelles étiquettes améliorées et effectueront une transformation de meilleure qualité.

Remarque : Le rôle utilisé pour écrire le jeu d'étiquettes généré sur le `OutputS3Path` est le rôle associé à la transformation du Machine Learning, spécifié dans l'`CreateMLTransformAPI`.

Demande

- `TransformId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation du Machine Learning.

- `OutputS3Path` – Obligatoire : chaîne UTF-8.

Chemin Amazon Simple Storage Service (Amazon S3) sur lequel vous générez l'ensemble d'étiquetage.

Réponse

- TaskRunId – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution de tâche.

Erreurs

- EntityNotFoundException
- InvalidInputException
- OperationTimeoutException
- InternalServiceException
- ConcurrentRunsExceededException

Action Get MLTask Run (Python : get_ml_task_run)

Permet d'obtenir les détails d'une exécution de tâche spécifique sur une transformation du Machine Learning. Les exécutions de tâches d'apprentissage automatique sont des tâches asynchrones exécutées AWS Glue en votre nom dans le cadre de différents flux de travail d'apprentissage automatique. Vous pouvez vérifier les statistiques de toutes les tâches exécutées en appelant GetMLTaskRun avec le TaskRunID et le TransformID de la transformation parent.

Demande

- TransformId – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation du Machine Learning.

- TaskRunId – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la tâche exécutée.

Réponse

- **TransformId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la tâche exécutée.

- **TaskRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution.

- **Status** – Chaîne UTF-8 (valeurs valides : RUNNING | FINISHED | FAILED | PENDING_EXECUTION | TIMED_OUT | CANCELING | CANCELED | RECEIVED_BY_TASKRUNNER).

Statut de la tâche exécutée.

- **LogGroupName** – Chaîne UTF-8.

Noms des groupes de journaux associés à la tâche exécutée.

- **Properties** – Un objet [TaskRunProperties](#).

Liste des propriétés associées à la tâche exécutée.

- **ErrorString** – Chaîne UTF-8.

Chaînes d'erreur associées à la tâche exécutée.

- **StartedOn** – Horodatage.

Date et heure de l'exécution de cette tâche.

- **LastModifiedOn** – Horodatage.

Date et heure de la dernière modification de cette exécution de tâche.

- **CompletedOn** – Horodatage.

Date et heure de fin de la dernière exécution de cette tâche.

- **ExecutionTime** – Nombre (entier).

Durée (en secondes) pendant laquelle la tâche exécutée a consommé des ressources.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Action Get MLTask Runs (Python : `get_ml_task_runs`)

Permet d'obtenir la liste des exécutions d'une transformation du Machine Learning. Les exécutions de tâches d'apprentissage automatique sont des tâches asynchrones exécutées AWS Glue en votre nom dans le cadre de différents flux de travail d'apprentissage automatique. Vous pouvez obtenir une liste triable et filtrable des exécutions de tâche du Machine Learning en appelant `GetMLTaskRuns` avec le `TransformID` de sa transformation parent et d'autres paramètres facultatifs, comme décrit dans cette section.

Cette opération renvoie la liste des exécutions historiques et doit être paginée.

Demande

- `TransformId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation du Machine Learning.

- `NextToken` – Chaîne UTF-8.

Jeton pour la pagination des résultats. La valeur par défaut est vide.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats à renvoyer.

- `Filter` – Un objet [TaskRunFilterCriteria](#).

Critères de filtre, dans la structure `TaskRunFilterCriteria`, pour la tâche exécutée.

- `Sort` – Un objet [TaskRunSortCriteria](#).

Critères de tri, dans la structure `TaskRunSortCriteria`, pour la tâche exécutée.

Réponse

- TaskRuns – Un tableau d'objets [TaskRun](#).

Liste des exécutions de tâches associées à la transformation.

- NextToken – Chaîne UTF-8.

Un jeton de pagination, si d'autres résultats sont disponibles.

Erreurs

- EntityNotFoundException
- InvalidInputException
- OperationTimeoutException
- InternalServiceException

Annuler l'action MLTask Exécuter (Python : `cancel_ml_task_run`)

Annule (arrête) une exécution de tâche. Les exécutions de tâches d'apprentissage automatique sont des tâches asynchrones exécutées AWS Glue en votre nom dans le cadre de différents flux de travail d'apprentissage automatique. Vous pouvez annuler une exécution de tâche du Machine Learning à tout moment en appelant `CancelMLTaskRun` avec le `TransformID` d'une transformation parent de la tâche exécutée et le `TaskRunId` de la tâche exécutée.

Demande

- TransformId – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation du Machine Learning.

- TaskRunId – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la tâche exécutée.

Réponse

- **TransformId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation du Machine Learning.

- **TaskRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de l'exécution de la tâche.

- **Status** – Chaîne UTF-8 (valeurs valides : RUNNING | FINISHED | FAILED | PENDING_EXECUTION | TIMED_OUT | CANCELING | CANCELED | RECEIVED_BY_TASKRUNNER).

Statut de cette exécution.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

StartExportLabelsTaskRun action (Python : `start_export_labels_task_run`)

Commence une tâche asynchrone pour exporter toutes les données étiquetées pour une transformation particulière. Cette tâche est le seul appel d'API lié à l'étiquetage qui ne fasse pas partie du flux de travail d'apprentissage actif classique. Vous utilisez généralement `StartExportLabelsTaskRun` lorsque vous souhaitez utiliser tous vos étiquettes existantes en même temps, par exemple lorsque vous souhaitez supprimer ou modifier les étiquettes qui ont été soumises précédemment comme vraies. Cette opération d'API accepte le `TransformId` dont vous souhaitez exporter les étiquettes et un chemin Amazon Simple Storage Service (Amazon S3) vers lequel exporter les étiquettes. L'opération renvoie un `TaskRunId`. Vous pouvez vérifier le statut de votre tâche d'exécuter en appelant l'API `GetMLTaskRun`.

Demande

- **TransformId** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation du Machine Learning.

- **OutputS3Path** – Obligatoire : chaîne UTF-8.

Chemin Amazon S3 où vous exportez les étiquettes.

Réponse

- **TaskRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de l'exécution de la tâche.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

StartImportLabelsTaskRun action (Python : `start_import_labels_task_run`)

Vous permet de fournir des étiquettes supplémentaires (exemples de vérité) à utiliser afin d'enseigner la transformation du Machine Learning et d'améliorer sa qualité. Cette opération d'API est généralement utilisée dans le cadre du processus d'apprentissage active qui commence par l'appel `StartMLLabelingSetGenerationTaskRun` et qui se traduit finalement par l'amélioration de la qualité de votre transformation de Machine Learning.

Une fois `StartMLLabelingSetGenerationTaskRun` terminé, le machine learning AWS Glue aura généré une série de questions pour que les humains y répondent. (La réponse à ces questions est souvent appelé « étiquette » dans les flux de travail du Machine Learning). Dans le cas de la transformation `FindMatches`, ces questions prennent la forme : « Quel est le bon moyen de regrouper conjointement ces lignes en groupes composés d'enregistrements correspondants ? »

Une fois le processus d'étiquetage terminé, les utilisateurs les téléchargent answers/labels en appelant `StartImportLabelsTaskRun`. Une fois `StartImportLabelsTaskRun` terminé, toutes les exécutions futures de la transformation du Machine Learning utilisent les nouvelles étiquettes améliorées et effectuent une transformation de meilleure qualité.

Par défaut, `StartMLLabelingSetGenerationTaskRun` apprend en permanence et associe toutes les étiquettes que vous chargez, sauf si vous définissez `Replace` sur `true`. Si vous définissez `Replace` sur `true`, `StartImportLabelsTaskRun` supprime et oublie toutes les étiquettes précédemment chargées et apprend uniquement à partir de l'ensemble exact que vous chargez. Le remplacement des étiquettes peuvent être utiles si vous vous rendez compte que vous avez précédemment téléchargé les étiquettes incorrectes et que vous pensez qu'elles ont une incidence négative sur la qualité de votre transformation.

Vous pouvez vérifier le statut de votre exécution de tâche en appelant l'opération `GetMLTaskRun`.

Demande

- `TransformId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de la transformation du Machine Learning.

- `InputS3Path` – Obligatoire : chaîne UTF-8.

Chemin Amazon Simple Storage Service (Amazon S3) à partir duquel vous importez les étiquettes.

- `ReplaceAllLabels` – Booléen.

Indique si vous souhaitez remplacer vos étiquettes existantes.

Réponse

- `TaskRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant unique de l'exécution de la tâche.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`

- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`

API Qualité des données

L'API Qualité des données décrit les types de données de qualité et inclut l'API permettant de créer, supprimer ou de mettre à jour des ensembles de règles, exécutions et évaluations.

Types de données

- [DataSource structure](#)
- [DataQualityRulesetListDetails structure](#)
- [DataQualityTargetTable structure](#)
- [DataQualityRulesetEvaluationRunDescription structure](#)
- [DataQualityRulesetEvaluationRunFilter structure](#)
- [DataQualityEvaluationRunAdditionalRunOptions structure](#)
- [DataQualityRuleRecommendationRunDescription structure](#)
- [DataQualityRuleRecommendationRunFilter structure](#)
- [DataQualityResult structure](#)
- [DataQualityAnalyzerResult structure](#)
- [DataQualityObservation structure](#)
- [MetricBasedObservation structure](#)
- [DataQualityMetricValues structure](#)
- [DataQualityRuleResult structure](#)
- [DataQualityResultDescription structure](#)
- [DataQualityResultFilterCriteria structure](#)
- [DataQualityRulesetFilterCriteria structure](#)
- [DataQualityAggregatedMetrics structure](#)
- [StatisticAnnotation structure](#)
- [TimestampedInclusionAnnotation structure](#)

- [AnnotationError structure](#)
- [DatapointInclusionAnnotation structure](#)
- [StatisticSummaryList liste](#)
- [StatisticSummary structure](#)
- [RunIdentifier structure](#)
- [StatisticModelResult structure](#)

DataSource structure

Source de données (AWS Glue table) pour laquelle vous souhaitez obtenir des résultats de qualité.

Champs

- `GlueTable` – Obligatoire : un objet [GlueTable](#).

Et une AWS Glue table.

DataQualityRulesetListDetails structure

Décrit un ensemble de règles de qualité des données renvoyé par `GetDataQualityRuleset`.

Champs

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'ensemble de règles de qualité des données.

- `Description` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de l'ensemble de règles de qualité des données.

- `CreatedOn` – Horodatage.

Date et heure de création de l'ensemble de règles de qualité des données.

- `LastModifiedOn` – Horodatage.

Date et heure de la dernière modification de l'ensemble de règles de qualité des données.

- `TargetTable` – Un objet [DataQualityTargetTable](#).

Un objet représentant une AWS Glue table.

- `RecommendationRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Lors de la création d'un ensemble de règles à partir d'une exécution de recommandation, cet ID d'exécution est généré pour relier les deux.

- `RuleCount` – Nombre (entier).

Nombre de règles dans l'ensemble de règles.

DataQualityTargetTable structure

Un objet représentant une AWS Glue table.

Champs

- `TableName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de la AWS Glue table.

- `DatabaseName` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la base de données dans laquelle se trouve la AWS Glue table.

- `CatalogId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant du catalogue où se trouve la AWS Glue table.

DataQualityRulesetEvaluationRunDescription structure

Décrit le résultat d'une exécution d'évaluation d'un ensemble de règles de qualité des données.

Champs

- `RunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution.

- **Status** – Chaîne UTF-8 (valeurs valides : RUNNING | FINISHED | FAILED | PENDING_EXECUTION | TIMED_OUT | CANCELING | CANCELED | RECEIVED_BY_TASKRUNNER).

Statut de cette exécution.

- **StartedOn** – Horodatage.

Date et heure de lancement de l'exécution.

- **DataSource** – Un objet [DataSource](#).

La source de données (une AWS Glue table) associée à l'exécution.

DataQualityRulesetEvaluationRunFilter structure

Critères de filtrage.

Champs

- **DataSource** – Obligatoire : un objet [DataSource](#).

Filtrez en fonction d'une source de données (une AWS Glue table) associée à l'exécution.

- **StartedBefore** – Horodatage.

Filtrez les résultats en fonction des exécutions qui ont débuté avant cette heure.

- **StartedAfter** – Horodatage.

Filtrez les résultats en fonction des exécutions qui ont débuté après cette heure.

DataQualityEvaluationRunAdditionalRunOptions structure

Options d'exécution supplémentaires que vous pouvez spécifier pour une exécution d'évaluation.

Champs

- **CloudWatchMetricsEnabled** – Booléen.

Activer ou non les CloudWatch métriques.

- **ResultsS3Prefix** – Chaîne UTF-8.

Préfixe permettant à Amazon S3 de stocker les résultats.

- CompositeRuleEvaluationMethod – Chaîne UTF-8 (valeurs valides : COLUMN | ROW).

Définissez la méthode d'évaluation des règles composites dans le jeu de règles sur ROW/
COLUMN

DataQualityRuleRecommendationRunDescription structure

Décrit le résultat de l'exécution d'une recommandation de règle de qualité des données.

Champs

- RunId – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution.

- Status – Chaîne UTF-8 (valeurs valides : RUNNING | FINISHED | FAILED | PENDING_EXECUTION | TIMED_OUT | CANCELING | CANCELED | RECEIVED_BY_TASKRUNNER).

Statut de cette exécution.

- StartedOn – Horodatage.

Date et heure de lancement de cette exécution.

- DataSource – Un objet [DataSource](#).

Source de données (AWS Glue table) associée à l'exécution de la recommandation.

DataQualityRuleRecommendationRunFilter structure

Filtre permettant de répertorier les exécutions de recommandations relatives à la qualité des données.

Champs

- DataSource – Obligatoire : un objet [DataSource](#).

Filtrez en fonction d'une source de données spécifiée (AWS Glue table).

- StartedBefore – Horodatage.

Filtrez en fonction de l'heure de début des résultats avant l'heure indiquée.

- `StartedAfter` – Horodatage.

Filtrez en fonction de l'heure de début des résultats après l'heure indiquée.

DataQualityResult structure

Décrit un résultat sur la qualité des données.

Champs

- `ResultId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de résultat unique pour le résultat en matière de qualité des données.

- `ProfileId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de profil pour le résultat de qualité des données.

- `Score` – Nombre (double), au plus égal à 1,0.

Score de qualité des données agrégées. Représente le rapport entre le nombre de règles transmises et le nombre total de règles.

- `DataSource` – Un objet [DataSource](#).

Table associée au résultat sur la qualité des données, le cas échéant.

- `RulesetName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'ensemble de règles associé au résultat sur la qualité des données.

- `EvaluationContext` – Chaîne UTF-8.

Dans le contexte d'une tâche dans AWS Glue Studio, chaque nœud du canevas se voit généralement attribuer un nom et les nœuds de qualité des données porteront un nom. Dans le cas de plusieurs nœuds, `evaluationContext` peut distinguer les nœuds.

- `StartedOn` – Horodatage.

Date et heure du début de cette exécution de l'évaluation de la qualité des données.

- **CompletedOn** – Horodatage.

Date et heure de fin de la dernière exécution de cette évaluation de la qualité des données.

- **JobName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de tâche associé au résultat sur la qualité des données, le cas échéant.

- **JobRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution de la tâche associé au résultat sur la qualité des données, le cas échéant.

- **RulesetEvaluationRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution unique de l'évaluation de l'ensemble de règles pour ce résultat sur la qualité des données.

- **RuleResults** – Un tableau d'objets [DataQualityRuleResult](#), 2 000 structures au maximum.

Liste d'objets `DataQualityRuleResult` représentant les résultats de chaque règle.

- **AnalyzerResults** – Un tableau d'objets [DataQualityAnalyzerResult](#), 2 000 structures au maximum.

Liste d'objets `DataQualityAnalyzerResult` représentant les résultats de chaque analyseur.

- **Observations** – Un tableau d'objets [DataQualityObservation](#), 50 structures maximum.

Liste d'objets `DataQualityObservation` représentant les observations générées après évaluation des règles et des analyseurs.

- **AggregatedMetrics** – Un objet [DataQualityAggregatedMetrics](#).

Récapitulatif des `DataQualityAggregatedMetrics` objets indiquant le nombre total de lignes et de règles traitées, y compris leurs pass/fail statistiques basées sur les résultats au niveau des lignes.

DataQualityAnalyzerResult structure

Décrit le résultat de l'évaluation d'un analyseur de qualité des données.

Champs

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'analyseur de qualité des données.

- **Description** – Chaîne UTF-8, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de l'analyseur de qualité des données.

- **EvaluationMessage** – Chaîne UTF-8, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Message d'évaluation.

- **EvaluatedMetrics** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est un nombre (double).

Carte des métriques associées à l'évaluation de l'analyseur.

DataQualityObservation structure

Décrit l'observation générée après évaluation des règles et des analyseurs.

Champs

- **Description** – Chaîne UTF-8, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de l'observation de la qualité des données.

- **MetricBasedObservation** – Un objet [MetricBasedObservation](#).

Objet de type `MetricBasedObservation` représentant l'observation basée sur des mesures de qualité des données évaluées.

MetricBasedObservation structure

Décrit l'observation basée sur les métriques générée sur la base des métriques de qualité des données évaluées.

Champs

- **MetricName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la métrique de qualité des données utilisée pour générer l'observation.

- **StatisticId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant de la statistique.

- **MetricValues** – Un objet [DataQualityMetricValues](#).

Objet de type `DataQualityMetricValues` représentant l'analyse de la valeur métrique de qualité des données.

- **NewRules** – Tableau de chaînes UTF-8.

Liste des nouvelles règles de qualité des données générées dans le cadre de l'observation sur la base de la valeur métrique de qualité des données.

DataQualityMetricValues structure

Décrit la valeur de la métrique de qualité des données en fonction de l'analyse des données historiques.

Champs

- **ActualValue** – Nombre (double).

La valeur réelle de la métrique de qualité des données.

- **ExpectedValue** – Nombre (double).

La valeur attendue de la métrique de qualité des données selon l'analyse des données historiques.

- **LowerLimit** – Nombre (double).

Limite inférieure de la valeur métrique de qualité des données selon l'analyse des données historiques.

- `UpperLimit` – Nombre (double).

Limite supérieure de la valeur métrique de qualité des données selon l'analyse des données historiques.

DataQualityRuleResult structure

Décrit le résultat de l'évaluation d'une règle de qualité des données.

Champs

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la règle de qualité des données.

- `Description` – Chaîne UTF-8, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de la règle de qualité des données.

- `EvaluationMessage` – Chaîne UTF-8, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Message d'évaluation.

- `Result` – Chaîne UTF-8 (valeurs valides : PASS | FAIL | ERROR).

État de réussite ou d'échec de la règle.

- `EvaluatedMetrics` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est un nombre (double).

Une carte des métriques associées à l'évaluation de la règle.

- `EvaluatedRule` – Chaîne UTF-8, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

La règle évaluée.

- **RuleMetrics** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est un nombre (double).

Carte contenant les métriques associées à l'évaluation de la règle en fonction des résultats au niveau des lignes.

DataQualityResultDescription structure

Décrit un résultat sur la qualité des données.

Champs

- **ResultId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de résultat unique pour ce résultat sur la qualité des données.

- **DataSource** – Un objet [DataSource](#).

Nom de la table associée au résultat sur la qualité des données.

- **JobName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la tâche associée au résultat en matière de qualité des données.

- **JobRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution de la tâche associé au résultat en matière de qualité des données.

- **StartedOn** – Horodatage.

Heure du début de l'exécution pour ce résultat en matière de qualité des données.

DataQualityResultFilterCriteria structure

Critères permettant de renvoyer des résultats en matière de qualité des données.

Champs

- `DataSource` – Un objet [DataSource](#).

Filtrez les résultats en fonction de la source de données spécifiée. Par exemple, récupérer tous les résultats d'une AWS Glue table.

- `JobName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Filtrez les résultats en fonction du nom de la tâche spécifiée.

- `JobRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Filtrez les résultats en fonction de l'ID d'exécution de la tâche spécifiée.

- `StartedAfter` – Horodatage.

Filtrez les résultats en fonction des exécutions qui ont débuté après cette heure.

- `StartedBefore` – Horodatage.

Filtrez les résultats en fonction des exécutions qui ont débuté avant cette heure.

DataQualityRulesetFilterCriteria structure

Critères permettant de filtrer les ensembles de règles de qualité des données.

Champs

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom des critères de filtrage de l'ensemble de règles.

- `Description` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description des critères de filtrage de l'ensemble de règles.

- `CreatedBefore` – Horodatage.

Filtre sur les ensembles de règles créés avant cette date.

- `CreatedAfter` – Horodatage.

Filtre sur les ensembles de règles créés après cette date.

- `LastModifiedBefore` – Horodatage.

Filtre sur les derniers ensembles de règles modifiés avant cette date.

- `LastModifiedAfter` – Horodatage.

Filtre sur les derniers ensembles de règles modifiés après cette date.

- `TargetTable` – Un objet [DataQualityTargetTable](#).

Nom et nom de la base de données de la table cible.

DataQualityAggregatedMetrics structure

Résumé des mesures indiquant le nombre total de lignes et de règles traitées, y compris leurs pass/fail statistiques basées sur les résultats au niveau des lignes.

Champs

- `TotalRowsProcessed` – Nombre (double).

Nombre total de lignes traitées lors de l'évaluation de la qualité des données.

- `TotalRowsPassed` – Nombre (double).

Nombre total de lignes ayant satisfait à toutes les règles de qualité des données applicables.

- `TotalRowsFailed` – Nombre (double).

Nombre total de lignes n'ayant pas respecté une ou plusieurs règles de qualité des données.

- `TotalRulesProcessed` – Nombre (double).

Nombre total de règles de qualité des données qui ont été évaluées.

- `TotalRulesPassed` – Nombre (double).

Nombre total de règles de qualité des données qui ont satisfait à leurs critères d'évaluation.

- `TotalRulesFailed` – Nombre (double).

Nombre total de règles de qualité des données qui n'ont pas répondu aux critères d'évaluation.

StatisticAnnotation structure

Une annotation statistique.

Champs

- `ProfileId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant du profil.

- `StatisticId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant de la statistique.

- `StatisticRecordedOn` – Horodatage.

Horodatage auquel la statistique annotée a été enregistrée.

- `InclusionAnnotation` – Un objet [TimestampedInclusionAnnotation](#).

L'annotation d'inclusion appliquée à la statistique.

TimestampedInclusionAnnotation structure

Une annotation d'inclusion horodatée.

Champs

- `Value` – Chaîne UTF-8 (valeurs valides : INCLUDE | EXCLUDE).

La valeur de l'annotation d'inclusion.

- `LastModifiedOn` – Horodatage.

Horodatage de la dernière modification de l'annotation d'inclusion.

AnnotationError structure

Une annotation qui a échoué.

Champs

- **ProfileId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de profil de l'annotation qui a échoué.

- **StatisticId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID statistique de l'annotation qui a échoué.

- **FailureReason** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Raison pour laquelle l'annotation a échoué.

DatapointInclusionAnnotation structure

Une annotation d'inclusion.

Champs

- **ProfileId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du profil de qualité des données auquel appartient la statistique.

- **StatisticId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant de la statistique.

- **InclusionAnnotation** – Chaîne UTF-8 (valeurs valides : INCLUDE | EXCLUDE).

Valeur d'annotation d'inclusion à appliquer à la statistique.

StatisticSummaryList liste

Une liste de `StatisticSummary`.

Tableau d'objets [StatisticSummary](#).

Une liste de `StatisticSummary`.

StatisticSummary structure

Informations récapitulatives relatives à une statistique.

Champs

- `StatisticId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant de la statistique.

- `ProfileId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant du profil.

- `RunIdentifier` – Un objet [RunIdentifier](#).

L'identifiant de course

- `StatisticName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Custom string pattern #16](#).

Le nom de la statistique.

- `DoubleValue` – Nombre (double).

La valeur de la statistique.

- `EvaluationLevel` – Chaîne UTF-8 (valeurs valides : `Dataset="DATASET" | Column="COLUMN" | Multicolumn="MULTICOLUMN"`).

Le niveau d'évaluation de la statistique. Valeurs possibles : `Dataset,Column,Multicolumn`.

- `ColumnsReferenced` – Tableau de chaînes UTF-8.

Liste des colonnes référencées par la statistique.

- **ReferencedDatasets** – Tableau de chaînes UTF-8.

Liste des ensembles de données référencés par la statistique.

- **StatisticProperties** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est une chaîne Description, d'une longueur ne dépassant pas 2048 octets, correspondant au [URI address multi-line string pattern](#).

AStatisticPropertiesMap, qui contient a NameString et DescriptionString

- **RecordedOn** – Horodatage.

Horodatage auquel la statistique a été enregistrée.

- **InclusionAnnotation** – Un objet [TimestampedInclusionAnnotation](#).

L'annotation d'inclusion pour la statistique.

RunIdentifier structure

Un identifiant de course.

Champs

- **RunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant d'exécution.

- **JobRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant Job Run.

StatisticModelResult structure

Le résultat du modèle statistique.

Champs

- `LowerBound` – Nombre (double).

La limite inférieure.

- `UpperBound` – Nombre (double).

La limite supérieure.

- `PredictedValue` – Nombre (double).

La valeur prévue.

- `ActualValue` – Nombre (double).

La valeur réelle.

- `Date` – Horodatage.

La date.

- `InclusionAnnotation` – Chaîne UTF-8 (valeurs valides : INCLUDE | EXCLUDE).

L'annotation d'inclusion.

Opérations

- [StartDataQualityRulesetEvaluationRun action \(Python : `start\_data\_quality\_ruleset\_evaluation\_run`\)](#)
- [CancelDataQualityRulesetEvaluationRun action \(Python : `cancel\_data\_quality\_ruleset\_evaluation\_run`\)](#)
- [GetDataQualityRulesetEvaluationRun action \(Python : `get\_data\_quality\_ruleset\_evaluation\_run`\)](#)
- [ListDataQualityRulesetEvaluationRuns action \(Python : `list\_data\_quality\_ruleset\_evaluation\_runs`\)](#)
- [StartDataQualityRuleRecommendationRun action \(Python : `start\_data\_quality\_rule\_recommendation\_run`\)](#)
- [CancelDataQualityRuleRecommendationRun action \(Python : `cancel\_data\_quality\_rule\_recommendation\_run`\)](#)
- [GetDataQualityRuleRecommendationRun action \(Python : `get\_data\_quality\_rule\_recommendation\_run`\)](#)
- [ListDataQualityRuleRecommendationRuns action \(Python : `list\_data\_quality\_rule\_recommendation\_runs`\)](#)

- [GetDataQualityResult action \(Python : `get\_data\_quality\_result`\)](#)
- [BatchGetDataQualityResult action \(Python : `batch\_get\_data\_quality\_result`\)](#)
- [ListDataQualityResults action \(Python : `list\_data\_quality\_results`\)](#)
- [CreateDataQualityRuleset action \(Python : `create\_data\_quality\_ruleset`\)](#)
- [DeleteDataQualityRuleset action \(Python : `delete\_data\_quality\_ruleset`\)](#)
- [GetDataQualityRuleset action \(Python : `get\_data\_quality\_ruleset`\)](#)
- [ListDataQualityRulesets action \(Python : `list\_data\_quality\_rulesets`\)](#)
- [UpdateDataQualityRuleset action \(Python : `update\_data\_quality\_ruleset`\)](#)
- [ListDataQualityStatistics action \(Python : `list\_data\_quality\_statistics`\)](#)
- [TimestampFilter structure](#)
- [CreateDataQualityRulesetRequest structure](#)
- [GetDataQualityRulesetResponse structure](#)
- [GetDataQualityResultResponse structure](#)
- [StartDataQualityRuleRecommendationRunRequest structure](#)
- [GetDataQualityRuleRecommendationRunResponse structure](#)
- [BatchPutDataQualityStatisticAnnotation action \(Python : `batch\_put\_data\_quality\_statistic\_annotation`\)](#)
- [GetDataQualityModel action \(Python : `get\_data\_quality\_model`\)](#)
- [GetDataQualityModelResult action \(Python : `get\_data\_quality\_model\_result`\)](#)
- [ListDataQualityStatisticAnnotations action \(Python : `list\_data\_quality\_statistic\_annotations`\)](#)
- [PutDataQualityProfileAnnotation action \(Python : `put\_data\_quality\_profile\_annotation`\)](#)

StartDataQualityRulesetEvaluationRun action (Python : `start_data_quality_ruleset_evaluation_run`)

Une fois que vous avez une définition d'ensemble de règles (recommandée ou la vôtre), vous appelez cette opération pour évaluer l'ensemble de règles par rapport à une source de données (AWS Glue table). L'évaluation calcule les résultats que vous pouvez récupérer à l'aide de l'API `GetDataQualityResult`.

Demande

- **DataSource** – Obligatoire : un objet [DataSource](#).

La source de données (AWS Glue table) associée à cette exécution.

- `Role` – Obligatoire : chaîne UTF-8.

IAM Rôle fourni pour chiffrer les résultats de l'exécution.

- `NumberOfWorkers` – Nombre (entier).

Nombre d'employés G.1X à utiliser dans l'exécution. La valeur par défaut est 5.

- `Timeout` – Nombre (entier), au moins égal à 1.

Délai d'expiration d'une exécution en minutes. Durée maximale pendant laquelle une exécution peut consommer des ressources avant qu'elle ne se termine et n'entre dans l'état `TIMEOUT`. La valeur par défaut est de 2 880 minutes (48 heures).

- `ClientToken` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Utilisée pour l'idempotence ; il est recommandé de la définir sur un ID aléatoire (tel qu'un UUID) afin d'éviter de créer ou de démarrer plusieurs instances de la même ressource.

- `AdditionalRunOptions` – Un objet [DataQualityEvaluationRunAdditionalRunOptions](#).

Options d'exécution supplémentaires que vous pouvez spécifier pour une exécution d'évaluation.

- `RulesetNames` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 10 chaînes maximum.

Liste de noms d'ensembles de règles.

- `AdditionalDataSources` – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est un objet [DataSource](#).

Une carte de chaînes de référence vers des sources de données supplémentaires que vous pouvez spécifier pour une exécution d'évaluation.

Réponse

- RunId – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution.

Erreurs

- InvalidInputException
- EntityNotFoundException
- OperationTimeoutException
- InternalServiceException
- ConflictException

CancelDataQualityRulesetEvaluationRun action (Python : `cancel_data_quality_ruleset_evaluation_run`)

Annule une exécution au cours de laquelle un ensemble de règles est évalué par rapport à une source de données.

Demande

- RunId – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- EntityNotFoundException
- InvalidInputException

- `OperationTimeoutException`
- `InternalServiceException`

GetDataQualityRulesetEvaluationRun action (Python : `get_data_quality_ruleset_evaluation_run`)

Récupère une exécution spécifique au cours de laquelle un ensemble de règles est évalué par rapport à une source de données.

Demande

- `RunId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution.

Réponse

- `RunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution.

- `DataSource` – Un objet [DataSource](#).

La source de données (une AWS Glue table) associée à cette exécution d'évaluation.

- `Role` – Chaîne UTF-8.

IAM Rôle fourni pour chiffrer les résultats de l'exécution.

- `NumberOfWorkers` – Nombre (entier).

Nombre d'employés G.1X à utiliser dans l'exécution. La valeur par défaut est 5.

- `Timeout` – Nombre (entier), au moins égal à 1.

Délai d'expiration d'une exécution en minutes. Durée maximale pendant laquelle une exécution peut consommer des ressources avant qu'elle ne se termine et n'entre dans l'état `TIMEOUT`. La valeur par défaut est de 2 880 minutes (48 heures).

- `AdditionalRunOptions` – Un objet [DataQualityEvaluationRunAdditionalRunOptions](#).

Options d'exécution supplémentaires que vous pouvez spécifier pour une exécution d'évaluation.

- **Status** – Chaîne UTF-8 (valeurs valides : RUNNING | FINISHED | FAILED | PENDING_EXECUTION | TIMED_OUT | CANCELING | CANCELED | RECEIVED_BY_TASKRUNNER).

Statut de cette exécution.

- **ErrorString** – Chaîne UTF-8.

Chaînes d'erreur associées à l'exécution.

- **StartedOn** – Horodatage.

Date et heure de lancement de cette exécution.

- **LastModifiedOn** – Horodatage.

Horodatage. Dernier moment où cette exécution de recommandation de règle de qualité des données a été modifiée.

- **CompletedOn** – Horodatage.

Date et heure de fin de cette exécution.

- **ExecutionTime** – Nombre (entier).

Durée (en secondes) pendant laquelle l'exécution a consommé des ressources.

- **RulesetNames** – Tableau de chaînes UTF-8, avec 1 chaîne minimum et 10 chaînes maximum.

Liste des noms des ensembles de règles utilisés pour l'exécution. Actuellement, ce paramètre ne peut avoir qu'un seul nom d'ensemble de règles.

- **ResultIds** – Tableau de chaînes UTF-8, avec 1 chaîne minimum et 10 chaînes maximum.

Liste des résultats IDs relatifs à la qualité des données obtenus lors de l'exécution.

- **AdditionalDataSources** – Tableau de mappage de paires valeur-clé.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaque valeur est un objet [DataSource](#).

Une carte de chaînes de référence vers des sources de données supplémentaires que vous pouvez spécifier pour une exécution d'évaluation.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

ListDataQualityRulesetEvaluationRuns action (Python : `list_data_quality_ruleset_evaluation_runs`)

Répertorie l'ensemble des exécutions répondant aux critères de filtrage, lorsqu'un ensemble de règles est évalué par rapport à une source de données.

Demande

- `Filter` – Un objet [DataQualityRulesetEvaluationRunFilter](#).

Critères de filtrage.

- `NextToken` – Chaîne UTF-8.

Jeton de pagination pour décaler les résultats.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats à renvoyer.

Réponse

- `Runs` – Un tableau d'objets [DataQualityRulesetEvaluationRunDescription](#).

Liste d'objets `DataQualityRulesetEvaluationRunDescription` représentant les exécutions d'un ensemble de règles en matière de qualité des données.

- `NextToken` – Chaîne UTF-8.

Un jeton de pagination, si d'autres résultats sont disponibles.

Erreurs

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

StartDataQualityRuleRecommendationRun action (Python : `start_data_quality_rule_recommendation_run`)

Lance une série de recommandations qui est utilisée pour générer des règles lorsque vous ne savez pas quelles règles écrire. AWS Glue Data Quality analyse les données et formule des recommandations pour un ensemble de règles potentiel. Vous pouvez ensuite trier l'ensemble de règles et modifier l'ensemble de règles généré selon votre convenance.

Les exécutions de recommandations sont automatiquement supprimées après 90 jours.

Demande

La demande de recommandation relative à la règle de qualité des données.

- `DataSource` – Obligatoire : un objet [DataSource](#).

La source de données (AWS Glue table) associée à cette exécution.

- `Role` – Obligatoire : chaîne UTF-8.

IAM Rôle fourni pour chiffrer les résultats de l'exécution.

- `NumberOfWorkers` – Nombre (entier).

Nombre d'employés G.1X à utiliser dans l'exécution. La valeur par défaut est 5.

- `Timeout` – Nombre (entier), au moins égal à 1.

Délai d'expiration d'une exécution en minutes. Durée maximale pendant laquelle une exécution peut consommer des ressources avant qu'elle ne se termine et n'entre dans l'état `TIMEOUT`. La valeur par défaut est de 2 880 minutes (48 heures).

- `CreatedRulesetName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'ensemble de règles.

- `DataQualitySecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité créée avec l'option de chiffrement de la qualité des données.

- `ClientToken` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Utilisée pour l'idempotence ; il est recommandé de la définir sur un ID aléatoire (tel qu'un UUID) afin d'éviter de créer ou de démarrer plusieurs instances de la même ressource.

Réponse

- `RunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution.

Erreurs

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ConflictException`

CancelDataQualityRuleRecommendationRun action (Python : `cancel_data_quality_rule_recommendation_run`)

Annule l'exécution de recommandation spécifiée qui était utilisée pour générer des règles.

Demande

- `RunId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

GetDataQualityRuleRecommendationRun action (Python : `get_data_quality_rule_recommendation_run`)

Obtient l'exécution de recommandation spécifiée qui a été utilisée pour générer des règles.

Demande

- `RunId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution.

Réponse

La réponse à la recommandation de règle de qualité des données exécutée.

- `RunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution.

- `DataSource` – Un objet [DataSource](#).

La source de données (une AWS Glue table) associée à cette exécution.

- `Role` – Chaîne UTF-8.

IAM Rôle fourni pour chiffrer les résultats de l'exécution.

- `NumberOfWorkers` – Nombre (entier).

Nombre d'employés G.1X à utiliser dans l'exécution. La valeur par défaut est 5.

- **Timeout** – Nombre (entier), au moins égal à 1.

Délai d'expiration d'une exécution en minutes. Durée maximale pendant laquelle une exécution peut consommer des ressources avant qu'elle ne se termine et n'entre dans l'état **TIMEOUT**. La valeur par défaut est de 2 880 minutes (48 heures).

- **Status** – Chaîne UTF-8 (valeurs valides : **RUNNING** | **FINISHED** | **FAILED** | **PENDING_EXECUTION** | **TIMED_OUT** | **CANCELING** | **CANCELED** | **RECEIVED_BY_TASKRUNNER**).

Statut de cette exécution.

- **ErrorString** – Chaîne UTF-8.

Chaînes d'erreur associées à l'exécution.

- **StartedOn** – Horodatage.

Date et heure de lancement de cette exécution.

- **LastModifiedOn** – Horodatage.

Horodatage. Dernier moment où cette exécution de recommandation de règle de qualité des données a été modifiée.

- **CompletedOn** – Horodatage.

Date et heure de fin de cette exécution.

- **ExecutionTime** – Nombre (entier).

Durée (en secondes) pendant laquelle l'exécution a consommé des ressources.

- **RecommendedRuleset** – Chaîne UTF-8, d'une longueur comprise entre 1 et 65536 octets.

À la fin de l'exécution d'une recommandation de règle de démarrage, un ensemble de règles recommandé est créé. Ce membre dispose de ces règles au format DQDL (Data Quality Definition Language).

- **CreatedRulesetName** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'ensemble de règles créé par l'exécution.

- **DataQualitySecurityConfiguration** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité créée avec l'option de chiffrement de la qualité des données.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

ListDataQualityRuleRecommendationRuns action (Python : `list_data_quality_rule_recommendation_runs`)

Répertorie les exécutions de recommandation répondant aux critères de filtrage.

Demande

- `Filter` – Un objet [DataQualityRuleRecommendationRunFilter](#).

Critères de filtrage.

- `NextToken` – Chaîne UTF-8.

Jeton de pagination pour décaler les résultats.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats à renvoyer.

Réponse

- `Runs` – Un tableau d'objets [DataQualityRuleRecommendationRunDescription](#).

Liste d'objets `DataQualityRuleRecommendationRunDescription`.

- `NextToken` – Chaîne UTF-8.

Un jeton de pagination, si d'autres résultats sont disponibles.

Erreurs

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

GetDataQualityResult action (Python : `get_data_quality_result`)

Récupère le résultat d'une évaluation des règles de qualité des données.

Demande

- `ResultId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de résultat unique pour le résultat en matière de qualité des données.

Réponse

La réponse pour le résultat relatif à la qualité des données.

- `ResultId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de résultat unique pour le résultat en matière de qualité des données.

- `ProfileId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de profil pour le résultat de qualité des données.

- `Score` – Nombre (double), au plus égal à 1,0.

Score de qualité des données agrégées. Représente le rapport entre le nombre de règles transmises et le nombre total de règles.

- `DataSource` – Un objet [DataSource](#).

Table associée au résultat sur la qualité des données, le cas échéant.

- `RulesetName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'ensemble de règles associé au résultat sur la qualité des données.

- `EvaluationContext` – Chaîne UTF-8.

Dans le contexte d'une tâche dans AWS Glue Studio, chaque nœud du canevas se voit généralement attribuer un nom et les nœuds de qualité des données porteront un nom. Dans le cas de plusieurs nœuds, `evaluationContext` peut distinguer les nœuds.

- `StartedOn` – Horodatage.

Date et heure du début de l'exécution de ce résultat en matière de qualité des données.

- `CompletedOn` – Horodatage.

Date et heure de fin de l'exécution de ce résultat en matière de qualité des données.

- `JobName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de tâche associé au résultat sur la qualité des données, le cas échéant.

- `JobRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution de la tâche associé au résultat sur la qualité des données, le cas échéant.

- `RulesetEvaluationRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution unique associé à l'évaluation de l'ensemble de règles.

- `RuleResults` – Un tableau d'objets [DataQualityRuleResult](#), 2 000 structures au maximum.

Liste d'objets `DataQualityRuleResult` représentant les résultats de chaque règle.

- `AnalyzerResults` – Un tableau d'objets [DataQualityAnalyzerResult](#), 2 000 structures au maximum.

Liste d'objets `DataQualityAnalyzerResult` représentant les résultats de chaque analyseur.

- `Observations` – Un tableau d'objets [DataQualityObservation](#), 50 structures maximum.

Liste d'objets `DataQualityObservation` représentant les observations générées après évaluation des règles et des analyseurs.

- `AggregatedMetrics` – Un objet [DataQualityAggregatedMetrics](#).

Récapitulatif des `DataQualityAggregatedMetrics` objets indiquant le nombre total de lignes et de règles traitées, y compris leurs pass/fail statistiques basées sur les résultats au niveau des lignes.

Erreurs

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `EntityNotFoundException`

BatchGetDataQualityResult action (Python : `batch_get_data_quality_result`)

Récupère une liste des résultats de qualité des données pour le résultat IDs spécifié.

Demande

- `ResultIds` – Obligatoire : Tableau de chaînes UTF-8, avec 1 chaîne minimum et 100 chaînes maximum.

Une liste de résultats uniques IDs pour les résultats de qualité des données.

Réponse

- `Results` – Obligatoire : Un tableau d'objets [DataQualityResult](#).

Liste d'objets `DataQualityResult` représentant les résultats en matière de qualité des données.

- `ResultsNotFound` – Tableau de chaînes UTF-8, avec 1 chaîne minimum et 100 chaînes maximum.

Liste des résultats IDs pour lesquels aucun résultat n'a été trouvé.

Erreurs

- `InvalidInputException`
- `OperationTimeoutException`

- `InternalServiceException`

ListDataQualityResults action (Python : `list_data_quality_results`)

Renvoie tous les résultats d'exécution en matière de qualité des données pour votre compte.

Demande

- `Filter` – Un objet [DataQualityResultFilterCriteria](#).

Critères de filtrage.

- `NextToken` – Chaîne UTF-8.

Jeton de pagination pour décaler les résultats.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats à renvoyer.

Réponse

- `Results` – Obligatoire : Un tableau d'objets [DataQualityResultDescription](#).

Liste d'objets `DataQualityResultDescription`.

- `NextToken` – Chaîne UTF-8.

Un jeton de pagination, si d'autres résultats sont disponibles.

Erreurs

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

CreateDataQualityRuleset action (Python : `create_data_quality_ruleset`)

Crée un ensemble de règles de qualité des données avec des règles DQDL appliquées à une table spécifiée AWS Glue .

Vous créez l'ensemble de règles au format DQDL (Data Quality Definition Language). Pour plus d'informations, consultez le guide du AWS Glue développeur.

Demande

Demande de création d'un ensemble de règles relatives à la qualité des données.

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom unique de l'ensemble de règles de qualité des données.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de l'ensemble de règles de qualité des données.

- **Ruleset** – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 65536 octets.

Ensemble de règles DQDL (Data Quality Definition Language). Pour plus d'informations, consultez le guide du AWS Glue développeur.

- **Tags** – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Liste de balises appliquées à l'ensemble de règles de qualité des données.

- **TargetTable** – Un objet [DataQualityTargetTable](#).

Table cible associée à l'ensemble de règles de qualité des données.

- **RecommendationRunId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution unique pour l'exécution recommandée.

- **DataQualitySecurityConfiguration** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité créée avec l'option de chiffrement de la qualité des données.

- **ClientToken** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Utilisée pour l'idempotence ; il est recommandé de la définir sur un ID aléatoire (tel qu'un UUID) afin d'éviter de créer ou de démarrer plusieurs instances de la même ressource.

Réponse

- Name – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom unique de l'ensemble de règles de qualité des données.

Erreurs

- `InvalidInputException`
- `AlreadyExistsException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ResourceNumberLimitExceededException`

DeleteDataQualityRuleset action (Python : `delete_data_quality_ruleset`)

Supprime un ensemble de règles de qualité des données.

Demande

- Name – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'ensemble de règles de qualité des données.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

GetDataQualityRuleset action (Python : `get_data_quality_ruleset`)

Renvoie un ensemble de règles existant par identifiant ou nom.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de l'ensemble de règles.

Réponse

Renvoie la réponse de l'ensemble de règles de qualité des données.

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de l'ensemble de règles.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de l'ensemble de règles.

- **Ruleset** – Chaîne UTF-8, d'une longueur comprise entre 1 et 65536 octets.

Ensemble de règles DQDL (Data Quality Definition Language). Pour plus d'informations, consultez le guide du AWS Glue développeur.

- **TargetTable** – Un objet [DataQualityTargetTable](#).

Nom et nom de la base de données de la table cible.

- **CreatedOn** – Horodatage.

Horodatage. Date et heure de création de cet ensemble de règles de qualité des données.

- **LastModifiedOn** – Horodatage.

Horodatage. Dernier moment où cet ensemble de règles de qualité des données a été modifié.

- `RecommendationRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Lors de la création d'un ensemble de règles à partir d'une exécution de recommandation, cet ID d'exécution est généré pour relier les deux.

- `DataQualitySecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité créée avec l'option de chiffrement de la qualité des données.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

ListDataQualityRulesets action (Python : `list_data_quality_rulesets`)

Renvoie une liste paginée d'ensembles de règles pour la liste de tables spécifiée. AWS Glue

Demande

- `NextToken` – Chaîne UTF-8.

Jeton de pagination pour décaler les résultats.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats à renvoyer.

- `Filter` – Un objet [DataQualityRulesetFilterCriteria](#).

Critères de filtrage.

- `Tags` – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Liste de balises de paire clé-valeur.

Réponse

- `Rulesets` – Un tableau d'objets [DataQualityRulesetListDetails](#).

Liste paginée d'ensembles de règles pour la liste de tables spécifiée. AWS Glue

- `NextToken` – Chaîne UTF-8.

Un jeton de pagination, si d'autres résultats sont disponibles.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

UpdateDataQualityRuleset action (Python : `update_data_quality_ruleset`)

Met à jour l'ensemble de règles de qualité des données spécifié.

Demande

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'ensemble de règles de qualité des données.

- `Description` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de l'ensemble de règles.

- `Ruleset` – Chaîne UTF-8, d'une longueur comprise entre 1 et 65536 octets.

Ensemble de règles DQDL (Data Quality Definition Language). Pour plus d'informations, consultez le guide du AWS Glue développeur.

Réponse

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'ensemble de règles de qualité des données.

- **Description** – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de l'ensemble de règles.

- **Ruleset** – Chaîne UTF-8, d'une longueur comprise entre 1 et 65536 octets.

Ensemble de règles DQDL (Data Quality Definition Language). Pour plus d'informations, consultez le guide du AWS Glue développeur.

Erreurs

- `EntityNotFoundException`
- `AlreadyExistsException`
- `IdempotentParameterMismatchException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ResourceNumberLimitExceededException`

ListDataQualityStatistics action (Python : `list_data_quality_statistics`)

Récupère une liste de statistiques sur la qualité des données.

Demande

- **StatisticId** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant de la statistique.

- `ProfileId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant du profil.

- `TimestampFilter` – Un objet [TimestampFilter](#).

Un filtre d'horodatage.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats à renvoyer dans cette demande.

- `NextToken` – Chaîne UTF-8.

Un jeton de pagination pour demander la page de résultats suivante.

Réponse

- `Statistics` – Un tableau d'objets [StatisticSummary](#).

Une `StatisticSummaryList`.

- `NextToken` – Chaîne UTF-8.

Un jeton de pagination pour demander la page de résultats suivante.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`

TimestampFilter structure

Un filtre d'horodatage.

Champs

- `RecordedBefore` – Horodatage.

Horodatage avant lequel les statistiques doivent être incluses dans les résultats.

- `RecordedAfter` – Horodatage.

Horodatage après lequel les statistiques doivent être incluses dans les résultats.

CreateDataQualityRulesetRequest structure

Demande de création d'un ensemble de règles relatives à la qualité des données.

Champs

- `Name` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom unique de l'ensemble de règles de qualité des données.

- `Description` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de l'ensemble de règles de qualité des données.

- `Ruleset` – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 65536 octets.

Ensemble de règles DQDL (Data Quality Definition Language). Pour plus d'informations, consultez le guide du AWS Glue développeur.

- `Tags` – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Liste de balises appliquées à l'ensemble de règles de qualité des données.

- `TargetTable` – Un objet [DataQualityTargetTable](#).

Table cible associée à l'ensemble de règles de qualité des données.

- `RecommendationRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution unique pour l'exécution recommandée.

- `DataQualitySecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité créée avec l'option de chiffrement de la qualité des données.

- `ClientToken` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Utilisée pour l'idempotence ; il est recommandé de la définir sur un ID aléatoire (tel qu'un UUID) afin d'éviter de créer ou de démarrer plusieurs instances de la même ressource.

GetDataQualityRulesetResponse structure

Renvoie la réponse de l'ensemble de règles de qualité des données.

Champs

- `Name` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de l'ensemble de règles.

- `Description` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Description de l'ensemble de règles.

- `Ruleset` – Chaîne UTF-8, d'une longueur comprise entre 1 et 65536 octets.

Ensemble de règles DQDL (Data Quality Definition Language). Pour plus d'informations, consultez le guide du AWS Glue développeur.

- `TargetTable` – Un objet [DataQualityTargetTable](#).

Nom et nom de la base de données de la table cible.

- `CreatedOn` – Horodatage.

Horodatage. Date et heure de création de cet ensemble de règles de qualité des données.

- `LastModifiedOn` – Horodatage.

Horodatage. Dernier moment où cet ensemble de règles de qualité des données a été modifié.

- `RecommendationRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Lors de la création d'un ensemble de règles à partir d'une exécution de recommandation, cet ID d'exécution est généré pour relier les deux.

- `DataQualitySecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité créée avec l'option de chiffrement de la qualité des données.

GetDataQualityResultResponse structure

La réponse pour le résultat relatif à la qualité des données.

Champs

- `ResultId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de résultat unique pour le résultat en matière de qualité des données.

- `ProfileId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'ID de profil pour le résultat de qualité des données.

- `Score` – Nombre (double), au plus égal à 1,0.

Score de qualité des données agrégées. Représente le rapport entre le nombre de règles transmises et le nombre total de règles.

- `DataSource` – Un objet [DataSource](#).

Table associée au résultat sur la qualité des données, le cas échéant.

- `RulesetName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'ensemble de règles associé au résultat sur la qualité des données.

- `EvaluationContext` – Chaîne UTF-8.

Dans le contexte d'une tâche dans AWS Glue Studio, chaque nœud du canevas se voit généralement attribuer un nom et les nœuds de qualité des données porteront un nom. Dans le cas de plusieurs nœuds, `evaluationContext` peut distinguer les nœuds.

- `StartedOn` – Horodatage.

Date et heure du début de l'exécution de ce résultat en matière de qualité des données.

- `CompletedOn` – Horodatage.

Date et heure de fin de l'exécution de ce résultat en matière de qualité des données.

- `JobName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom de tâche associé au résultat sur la qualité des données, le cas échéant.

- `JobRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution de la tâche associé au résultat sur la qualité des données, le cas échéant.

- `RulesetEvaluationRunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID d'exécution unique associé à l'évaluation de l'ensemble de règles.

- `RuleResults` – Un tableau d'objets [DataQualityRuleResult](#), 2 000 structures au maximum.

Liste d'objets `DataQualityRuleResult` représentant les résultats de chaque règle.

- `AnalyzerResults` – Un tableau d'objets [DataQualityAnalyzerResult](#), 2 000 structures au maximum.

Liste d'objets `DataQualityAnalyzerResult` représentant les résultats de chaque analyseur.

- `Observations` – Un tableau d'objets [DataQualityObservation](#), 50 structures maximum.

Liste d'objets `DataQualityObservation` représentant les observations générées après évaluation des règles et des analyseurs.

- `AggregatedMetrics` – Un objet [DataQualityAggregatedMetrics](#).

Récapitulatif des `DataQualityAggregatedMetrics` objets indiquant le nombre total de lignes et de règles traitées, y compris leurs pass/fail statistiques basées sur les résultats au niveau des lignes.

StartDataQualityRuleRecommendationRunRequest structure

La demande de recommandation relative à la règle de qualité des données.

Champs

- `DataSource` – Obligatoire : un objet [DataSource](#).

La source de données (AWS Glue table) associée à cette exécution.

- `Role` – Obligatoire : chaîne UTF-8.

IAM Rôle fourni pour chiffrer les résultats de l'exécution.

- `NumberOfWorkers` – Nombre (entier).

Nombre d'employés G.1X à utiliser dans l'exécution. La valeur par défaut est 5.

- `Timeout` – Nombre (entier), au moins égal à 1.

Délai d'expiration d'une exécution en minutes. Durée maximale pendant laquelle une exécution peut consommer des ressources avant qu'elle ne se termine et n'entre dans l'état TIMEOUT. La valeur par défaut est de 2 880 minutes (48 heures).

- `CreatedRulesetName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'ensemble de règles.

- `DataQualitySecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité créée avec l'option de chiffrement de la qualité des données.

- `ClientToken` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Utilisée pour l'idempotence ; il est recommandé de la définir sur un ID aléatoire (tel qu'un UUID) afin d'éviter de créer ou de démarrer plusieurs instances de la même ressource.

GetDataQualityRuleRecommendationRunResponse structure

La réponse à la recommandation de règle de qualité des données exécutée.

Champs

- `RunId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Identifiant d'exécution unique associé à cette exécution.

- `DataSource` – Un objet [DataSource](#).

La source de données (une AWS Glue table) associée à cette exécution.

- `Role` – Chaîne UTF-8.

IAM Rôle fourni pour chiffrer les résultats de l'exécution.

- `NumberOfWorkers` – Nombre (entier).

Nombre d'employés G.1X à utiliser dans l'exécution. La valeur par défaut est 5.

- `Timeout` – Nombre (entier), au moins égal à 1.

Délai d'expiration d'une exécution en minutes. Durée maximale pendant laquelle une exécution peut consommer des ressources avant qu'elle ne se termine et n'entre dans l'état TIMEOUT. La valeur par défaut est de 2 880 minutes (48 heures).

- `Status` – Chaîne UTF-8 (valeurs valides : RUNNING | FINISHED | FAILED | PENDING_EXECUTION | TIMED_OUT | CANCELING | CANCELED | RECEIVED_BY_TASKRUNNER).

Statut de cette exécution.

- `ErrorString` – Chaîne UTF-8.

Chaînes d'erreur associées à l'exécution.

- `StartedOn` – Horodatage.

Date et heure de lancement de cette exécution.

- `LastModifiedOn` – Horodatage.

Horodatage. Dernier moment où cette exécution de recommandation de règle de qualité des données a été modifiée.

- `CompletedOn` – Horodatage.

Date et heure de fin de cette exécution.

- `ExecutionTime` – Nombre (entier).

Durée (en secondes) pendant laquelle l'exécution a consommé des ressources.

- `RecommendedRuleset` – Chaîne UTF-8, d'une longueur comprise entre 1 et 65536 octets.

À la fin de l'exécution d'une recommandation de règle de démarrage, un ensemble de règles recommandé est créé. Ce membre dispose de ces règles au format DQDL (Data Quality Definition Language).

- `CreatedRulesetName` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de l'ensemble de règles créé par l'exécution.

- `DataQualitySecurityConfiguration` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la configuration de sécurité créée avec l'option de chiffrement de la qualité des données.

BatchPutDataQualityStatisticAnnotation action (Python : `batch_put_data_quality_statistic_annotation`)

Annotez les points de données au fil du temps pour une statistique de qualité des données spécifique.

Demande

- `InclusionAnnotations` – Obligatoire : Un tableau d'objets [DatapointInclusionAnnotation](#).

Une liste `DatapointInclusionAnnotation` de.

- `ClientToken` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Jeton client.

Réponse

- `FailedInclusionAnnotations` – Un tableau d'objets [AnnotationError](#).

Une liste `AnnotationError` de.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `ResourceNumberLimitExceededException`

GetDataQualityModel action (Python : `get_data_quality_model`)

Récupérez l'état d'entraînement du modèle ainsi que des informations supplémentaires (`CompletedOn`, `StartedOn`, `FailureReason`).

Demande

- `StatisticId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant de la statistique.

- `ProfileId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant du profil.

Réponse

- `Status` – Chaîne UTF-8 (valeurs valides : `RUNNING` | `SUCCEEDED` | `FAILED`).

État d'apprentissage du modèle de qualité des données.

- `StartedOn` – Horodatage.

Horodatage du début de l'entraînement au modèle de qualité des données.

- `CompletedOn` – Horodatage.

Horodatage auquel l'entraînement du modèle de qualité des données s'est terminé.

- `FailureReason` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

La raison de l'échec de l'entraînement.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

GetDataQualityModelResult action (Python : `get_data_quality_model_result`)

Récupérez les prédictions d'une statistique pour un ID de profil donné.

Demande

- `StatisticId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant de la statistique.

- `ProfileId` – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant du profil.

Réponse

- `CompletedOn` – Horodatage.

Horodatage auquel l'entraînement du modèle de qualité des données s'est terminé.

- `Model` – Un tableau d'objets [StatisticModelResult](#).

Une liste de `StatisticModelResult`

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

ListDataQualityStatisticAnnotations action (Python : `list_data_quality_statistic_annotations`)

Récupérez les annotations d'une statistique de qualité des données.

Demande

- `StatisticId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant de la statistique.

- `ProfileId` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

L'identifiant du profil.

- `TimestampFilter` – Un objet [TimestampFilter](#).

Un filtre d'horodatage.

- `MaxResults` – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats à renvoyer dans cette demande.

- `NextToken` – Chaîne UTF-8.

Un jeton de pagination pour récupérer le prochain ensemble de résultats.

Réponse

- `Annotations` – Un tableau d'objets [StatisticAnnotation](#).

Une liste de `StatisticAnnotation` ceux appliqués à la statistique

- `NextToken` – Chaîne UTF-8.

Un jeton de pagination pour récupérer le prochain ensemble de résultats.

Erreurs

- `InvalidInputException`
- `InternalServiceException`

PutDataQualityProfileAnnotation action (Python : put_data_quality_profile_annotation)

Annotez tous les points de données d'un profil.

Demande

- **ProfileId** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID du profil de surveillance de la qualité des données à annoter.

- **InclusionAnnotation** – Obligatoire : Chaîne UTF-8 (valeurs valides : INCLUDE | EXCLUDE).

Valeur d'annotation d'inclusion à appliquer au profil.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`

API Détection des données sensibles

L'API de détection des données sensibles décrit les APIs méthodes utilisées pour détecter les données sensibles dans les colonnes et les lignes de vos données structurées.

Types de données

- [CustomEntityType structure](#)

CustomEntityType structure

Objet représentant un modèle personnalisé permettant de détecter des données sensibles sur les colonnes et les lignes de vos données structurées.

Champs

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du modèle personnalisé qui permet de le récupérer ou de le supprimer ultérieurement. Ce nom doit être unique par AWS compte.

- **RegexString** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaîne d'expression régulière utilisée pour détecter des données sensibles dans un modèle personnalisé.

- **ContextWords** – Tableau de chaînes UTF-8, entre 1 et 20 chaînes.

Une liste de mots contextuels. Si aucun de ces mots contextuels n'est trouvé à proximité de l'expression régulière, les données ne seront pas détectées en tant que données sensibles.

Si aucun mot contextuel n'est transmis, seule une expression régulière est vérifiée.

Opérations

- [CreateCustomEntityType action \(Python : create_custom_entity_type\)](#)
- [DeleteCustomEntityType action \(Python : delete_custom_entity_type\)](#)
- [GetCustomEntityType action \(Python : get_custom_entity_type\)](#)
- [BatchGetCustomEntityTypes action \(Python : batch_get_custom_entity_types\)](#)
- [ListCustomEntityTypes action \(Python : list_custom_entity_types\)](#)

CreateCustomEntityType action (Python : create_custom_entity_type)

Crée un modèle personnalisé utilisé pour détecter les données sensibles sur les colonnes et les lignes de vos données structurées.

Chaque modèle personnalisé que vous créez spécifie une expression régulière et une liste facultative de mots contextuels. Si aucun mot contextuel n'est transmis, seule une expression régulière est vérifiée.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du modèle personnalisé qui permet de le récupérer ou de le supprimer ultérieurement. Ce nom doit être unique par AWS compte.

- **RegexString** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaîne d'expression régulière utilisée pour détecter des données sensibles dans un modèle personnalisé.

- **ContextWords** – Tableau de chaînes UTF-8, entre 1 et 20 chaînes.

Une liste de mots contextuels. Si aucun de ces mots contextuels n'est trouvé à proximité de l'expression régulière, les données ne seront pas détectées en tant que données sensibles.

Si aucun mot contextuel n'est transmis, seule une expression régulière est vérifiée.

- **Tags** – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Liste de balises appliquées à un type d'entité personnalisé.

Réponse

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du modèle personnalisé que vous avez créé.

Erreurs

- `AccessDeniedException`
- `AlreadyExistsException`
- `IdempotentParameterMismatchException`
- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

DeleteCustomEntityType action (Python : `delete_custom_entity_type`)

Supprime un modèle personnalisé en spécifiant son nom.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom du modèle personnalisé que vous souhaitez supprimer.

Réponse

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom du modèle personnalisé que vous avez supprimé.

Erreurs

- `EntityNotFoundException`
- `AccessDeniedException`
- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

GetCustomEntityType action (Python : `get_custom_entity_type`)

Récupère les détails d'un modèle personnalisé en spécifiant son nom.

Demande

- **Name** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom du modèle personnalisé que vous souhaitez récupérer.

Réponse

- **Name** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Le nom du modèle personnalisé que vous avez récupéré.

- **RegexString** – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Chaîne d'expression régulière utilisée pour détecter des données sensibles dans un modèle personnalisé.

- **ContextWords** – Tableau de chaînes UTF-8, entre 1 et 20 chaînes.

Liste de mots contextuels, s'il est spécifié lors de la création du modèle personnalisé. Si aucun de ces mots contextuels n'est trouvé à proximité de l'expression régulière, les données ne seront pas détectées en tant que données sensibles.

Erreurs

- `EntityNotFoundException`
- `AccessDeniedException`
- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

BatchGetCustomEntityTypes action (Python : `batch_get_custom_entity_types`)

Récupère les détails des modèles personnalisés spécifiés par une liste de noms.

Demande

- Names – Obligatoire : tableau de chaînes UTF-8, avec 1 chaîne minimum et 50 chaînes maximum.

Liste des noms des modèles personnalisés que vous souhaitez récupérer.

Réponse

- CustomEntityTypes – Un tableau d'objets [CustomEntityType](#).

Une liste d'objets CustomEntityType représentant les modèles personnalisés que vous avez créés.

- CustomEntityTypesNotFound – Tableau de chaînes UTF-8, entre 1 et 50 chaînes.

Liste des noms de modèles personnalisés qui ont été introuvables.

Erreurs

- InvalidInputException
- InternalServiceException
- OperationTimeoutException

ListCustomEntityTypes action (Python : `list_custom_entity_types`)

Répertorie tous les modèles personnalisés qui ont été créés.

Demande

- NextToken – Chaîne UTF-8.

Jeton de pagination pour décaler les résultats.

- MaxResults – Nombre (entier), compris entre 1 et 1 000.

Nombre maximal de résultats à renvoyer.

- Tags – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Liste de balises de paire clé-valeur.

Réponse

- CustomEntityTypes – Un tableau d'objets [CustomEntityType](#).

Une liste d'objets CustomEntityType représentant des motifs personnalisés.

- NextToken – Chaîne UTF-8.

Un jeton de pagination, si d'autres résultats sont disponibles.

Erreurs

- InvalidInputException
- OperationTimeoutException
- InternalServiceException

Marquage APIs AWS Glue

Types de données

- [Structure Tag](#)

Structure Tag

L'objet Tag représente une étiquette que vous pouvez attribuer à une AWS ressource. Chaque balise est constituée d'une clé et d'une valeur facultative que vous définissez.

Pour plus d'informations sur les balises et le contrôle de l'accès aux ressources dans AWS Glue, voir [AWS Tags in AWS Glue et Specifying AWS Glue Resource ARNs](#) dans le guide du développeur.

Champs

- **key** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Identification de balise. La clé est obligatoire lorsque vous créez une balise sur un objet. La clé est sensible à la casse et ne doit pas contenir le préfixe aws.

- **value** – Chaîne UTF-8, d'une longueur maximale de 256 octets.

Valeur de balise. La valeur est facultative lorsque vous créez une balise sur un objet. La valeur est sensible à la casse et ne doit pas contenir le préfixe aws.

Opérations

- [TagResource action \(Python : tag_resource\)](#)
- [UntagResource action \(Python : untag_resource\)](#)
- [GetTags action \(Python : get_tags\)](#)

TagResource action (Python : tag_resource)

Ajoute des balises à une ressource. Une étiquette est une étiquette que vous pouvez attribuer à une AWS ressource. Dans AWS Glue, vous ne pouvez étiqueter que certaines ressources. Pour obtenir des informations sur les ressources que vous pouvez baliser, veuillez consulter la rubrique [Balises AWS dans AWS Glue](#).

Outre les autorisations de balisage liées aux balises d'appel APIs, vous devez également avoir l'glue:GetConnectionautorisation de baliser les appels APIs sur les connexions et l'glue:GetDatabaseautorisation de baliser les appels sur les bases de données APIs .

Demande

- **ResourceArn** – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

L'ARN de la AWS Glue ressource à laquelle ajouter les balises. Pour plus d'informations sur les AWS Glue ressources ARNs, consultez le [modèle de chaîne AWS Glue ARN](#).

- **TagsToAdd** – Obligatoire : Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Balises à ajouter à cette ressource.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `ResourceNotFoundException`

UntagResource action (Python : `untag_resource`)

Supprime les balises spécifiées d'une ressource d'intégration.

Demande

- `ResourceArn` – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

Le nom de ressource Amazon (ARN) de la ressource d'intégration.

- `TagsToRemove` – Obligatoire : Tableau de chaînes UTF-8, avec 50 chaînes maximum.

Liste des balises de métadonnées à supprimer de la ressource.

Réponse

- Paramètres d'absence de réponse.

Erreurs

- `ResourceNotFoundException`

GetTags action (Python : `get_tags`)

Récupère la liste des balises associées à une ressource.

Demande

- **ResourceArn** – Obligatoire : chaîne UTF-8, d'une longueur comprise entre 1 et 10 240 octets, correspondant au [Custom string pattern #49](#).

Amazon Resource Name (ARN) de la ressource pour laquelle récupérer les balises.

Réponse

- **Tags** – Tableau de mappage de paires clé-valeur, avec 50 paires au maximum.

Chaque clé est une chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Chaque valeur est une chaîne UTF-8, d'une longueur maximale de 256 octets.

Balises demandées.

Erreurs

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `EntityNotFoundException`

Types de données courants

Les types de données courants décrivent des types de données courants variés dans AWS Glue.

Structure de balise

L'`Tag` objet représente une étiquette que vous pouvez attribuer à une AWS ressource. Chaque balise est constituée d'une clé et d'une valeur facultative que vous définissez.

Pour plus d'informations sur les balises et le contrôle de l'accès aux ressources dans AWS Glue, voir [AWS Tags in AWS Glue et Specifying AWS Glue Resource ARNs](#) dans le guide du développeur.

Champs

- **key** – Chaîne UTF-8, d'une longueur comprise entre 1 et 128 octets.

Identification de balise. La clé est obligatoire lorsque vous créez une balise sur un objet. La clé est sensible à la casse et ne doit pas contenir le préfixe aws.

- `value` – Chaîne UTF-8, d'une longueur maximale de 256 octets.

Valeur de balise. La valeur est facultative lorsque vous créez une balise sur un objet. La valeur est sensible à la casse et ne doit pas contenir le préfixe aws.

DecimalNumber structure

Contient une valeur numérique au format décimal.

Champs

- `UnscaledValue` – obligatoire : blob.

Valeur numérique non mise à l'échelle.

- `Scale` – obligatoire : nombre (entier).

Échelle qui détermine où la virgule décimale tombe dans la valeur non mise à l'échelle.

ErrorDetail structure

Contient des informations détaillées sur une erreur.

Champs

- `ErrorCode` – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Code associé à cette erreur.

- `ErrorMessage` – Chaîne de description, d'une longueur maximale de 2 048 octets, correspondant au [URI address multi-line string pattern](#).

Message décrivant l'erreur.

PropertyPredicate structure

Définit un prédicat de propriété.

Champs

- **Key**— Chaîne de valeurs d'une longueur d'au moins 1 ou de 1 024 octets.

Clé de la propriété.

- **Value**— Chaîne de valeurs d'une longueur d'au moins 1 ou de 1 024 octets.

Valeur de la propriété.

- **Comparator** – Chaîne UTF-8 (valeurs valides : EQUALS | GREATER_THAN | LESS_THAN | GREATER_THAN_EQUALS | LESS_THAN_EQUALS).

Comparateur utilisé pour comparer cette propriété à d'autres.

ResourceUri structure

Les ressources URIs de la fonction for.

Champs

- **ResourceType** – Chaîne UTF-8 (valeurs valides : JAR | FILE | ARCHIVE).

Type de la ressource.

- **Uri** – Identificateur de ressource uniforme (URI), d'une longueur comprise entre 1 et 1024 octets, correspondant au [URI address multi-line string pattern](#).

URI pour accéder à la ressource.

ColumnStatistics structure

Représente les statistiques au niveau de la colonne générées pour une table ou une partition.

Champs

- **ColumnName** – Obligatoire : Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la colonne à laquelle appartiennent les statistiques.

- **ColumnType** – obligatoire : saisissez le nom, d'une longueur maximale de 20 000 octets, correspondant à [Single-line string pattern](#).

Type de données de la colonne.

- AnalyzedTime – obligatoire : horodatage.

Horodatage du moment où les statistiques de colonne ont été générées.

- StatisticsData – Obligatoire : un objet [ColumnStatisticsData](#).

ColumnStatisticData qui contient les valeurs de données statistiques.

ColumnStatisticsError structure

Encapsule un objet ColumnStatistics qui a échoué et la raison de l'échec.

Champs

- ColumnStatistics – Un objet [ColumnStatistics](#).

ColumnStatistics de la colonne.

- Error – Un objet [ErrorDetail](#).

Message d'erreur avec la raison de l'échec d'une opération.

ColumnError structure

Encapsule un nom de colonne qui a échoué et la raison de l'échec.

Champs

- ColumnName – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

Nom de la colonne ayant échoué.

- Error – Un objet [ErrorDetail](#).

Message d'erreur avec la raison de l'échec d'une opération.

ColumnStatisticsData structure

Contient chacun des types de données statistiques de colonne. Un seul objet de données doit être défini et indiqué par l'attribut Type.

Champs

- Type – obligatoire : chaîne UTF-8 (valeurs valides : BOOLEAN | DATE | DECIMAL | DOUBLE | LONG | STRING | BINARY).

Type de données statistiques de colonne.

- BooleanColumnStatisticsData – Un objet [BooleanColumnStatisticsData](#).

Données statistiques de colonne booléennes.

- DateColumnStatisticsData – Un objet [DateColumnStatisticsData](#).

Données statistiques de colonne de date.

- DecimalColumnStatisticsData – Un objet [DecimalColumnStatisticsData](#).

Données statistiques sur les colonnes décimales. UnscaledValues à l'intérieur se trouvent des objets binaires codés en Base64 stockant des représentations complémentaires à deux de la valeur décimale non mise à l'échelle.

- DoubleColumnStatisticsData – Un objet [DoubleColumnStatisticsData](#).

Données statistiques à double colonne.

- LongColumnStatisticsData – Un objet [LongColumnStatisticsData](#).

Données statistiques de colonne longue.

- StringColumnStatisticsData – Un objet [StringColumnStatisticsData](#).

Données statistiques de colonne de chaîne.

- BinaryColumnStatisticsData – Un objet [BinaryColumnStatisticsData](#).

Données de statistiques de colonne binaire.

BooleanColumnStatisticsData structure

Définit les statistiques de colonne prises en charge pour les colonnes de données booléennes.

Champs

- `NumberOfTrues` – obligatoire : nombre (entier), pas plus que None (Aucun).

Nombre de valeurs true dans la colonne.

- `NumberOfFalses` – obligatoire : nombre (entier), pas plus que None (Aucun).

Nombre de valeurs false dans la colonne.

- `NumberOfNulls` – obligatoire : nombre (entier), pas plus que None (Aucun).

Nombre de valeurs null dans la colonne.

DateColumnStatisticsData structure

Définit les statistiques de colonne prises en charge pour les colonnes de données d'horodatage.

Champs

- `MinimumValue` – Horodatage.

Valeur la plus faible dans la colonne.

- `MaximumValue` – Horodatage.

Valeur la plus élevée dans la colonne.

- `NumberOfNulls` – obligatoire : nombre (entier), pas plus que None (Aucun).

Nombre de valeurs null dans la colonne.

- `NumberOfDistinctValues` – obligatoire : nombre (entier), pas plus que None (Aucun).

Nombre de valeurs distinctes dans une colonne.

DecimalColumnStatisticsData structure

Définit les statistiques de colonne prises en charge pour les colonnes de données à virgule fixe.

Champs

- `MinimumValue` – Un objet [DecimalNumber](#).

Valeur la plus faible dans la colonne.

- `MaximumValue` – Un objet [DecimalNumber](#).

Valeur la plus élevée dans la colonne.

- `NumberOfNulls` – obligatoire : nombre (entier), pas plus que `None` (Aucun).

Nombre de valeurs null dans la colonne.

- `NumberOfDistinctValues` – obligatoire : nombre (entier), pas plus que `None` (Aucun).

Nombre de valeurs distinctes dans une colonne.

DoubleColumnStatisticsData structure

Définit les statistiques de colonne prises en charge pour les colonnes de données à virgule flottante.

Champs

- `MinimumValue` – Nombre (double).

Valeur la plus faible dans la colonne.

- `MaximumValue` – Nombre (double).

Valeur la plus élevée dans la colonne.

- `NumberOfNulls` – obligatoire : nombre (entier), pas plus que `None` (Aucun).

Nombre de valeurs null dans la colonne.

- `NumberOfDistinctValues` – obligatoire : nombre (entier), pas plus que `None` (Aucun).

Nombre de valeurs distinctes dans une colonne.

LongColumnStatisticsData structure

Définit les statistiques de colonne prises en charge pour les colonnes de données entières.

Champs

- `MinimumValue` – Nombre (long).

Valeur la plus faible dans la colonne.

- `MaximumValue` – Nombre (long).

Valeur la plus élevée dans la colonne.

- `NumberOfNulls` – obligatoire : nombre (entier), pas plus que None (Aucun).

Nombre de valeurs null dans la colonne.

- `NumberOfDistinctValues` – obligatoire : nombre (entier), pas plus que None (Aucun).

Nombre de valeurs distinctes dans une colonne.

StringColumnStatisticsData structure

Définit les statistiques de colonne prises en charge pour les valeurs de données de séquence de caractères.

Champs

- `MaxLength` – obligatoire : nombre (entier), pas plus que None (Aucun).

Taille de la chaîne la plus longue dans la colonne.

- `AverageLength` – obligatoire : nombre (double), pas plus que None (Aucun).

Longueur moyenne de la chaîne dans la colonne.

- `NumberOfNulls` – obligatoire : nombre (entier), pas plus que None (Aucun).

Nombre de valeurs null dans la colonne.

- `NumberOfDistinctValues` – obligatoire : nombre (entier), pas plus que None (Aucun).

Nombre de valeurs distinctes dans une colonne.

BinaryColumnStatisticsData structure

Définit les statistiques de colonne prises en charge pour les valeurs de données de séquence de bits.

Champs

- `MaxLength` – obligatoire : nombre (entier), pas plus que None (Aucun).

Taille de la séquence de bits la plus longue de la colonne.

- `AverageLength` – obligatoire : nombre (double), pas plus que None (Aucun).

Longueur moyenne de la séquence de bits dans la colonne.

- `NumberOfNulls` – obligatoire : nombre (entier), pas plus que `None` (Aucun).

Nombre de valeurs null dans la colonne.

Modèles de chaîne

L'API utilise les expressions régulières suivantes pour définir le contenu valide pour différents paramètres et membres de chaîne :

- Modèle de chaîne à ligne unique – `"[\u0020-\uD7FF\uE000-\uFFFF\uD800\uDC00-\uDBFF\uDFFF\t]*"`
- Modèle de chaîne à plusieurs lignes d'adresse URI – `"[\u0020-\uD7FF\uE000-\uFFFF\uD800\uDC00-\uDBFF\uDFFF\r\n\t]*"`
- Modèle de chaîne Logstash Grok – `"[\u0020-\uD7FF\uE000-\uFFFF\uD800\uDC00-\uDBFF\uDFFF\r\t]*"`
- Modèle de chaîne d'identifiant – `"[A-Za-z_][A-Za-z0-9_]*"`
- Modèle de chaîne ARN AWS IAM – `"arn:aws:iam::\d{12}:role/.*"`
- Modèle de chaîne de version – `"^[a-zA-Z0-9-_]+$"`
- Modèle de chaîne de groupe de journaux – `"[\.\.-_/#A-Za-z0-9]+"`
- Modèle de chaîne de flux de journaux – `"[^:]*"`
- Modèle de chaîne personnalisée #10 – `"[a-zA-Z0-9-_]+"`
- Modèle de chaîne personnalisée #11 – `"[-a-zA-Z0-9+="/:~_]*"`
- Modèle de chaîne personnalisée #12 – `"[\S\s]*"`
- Modèle de chaîne personnalisée #13 – `".*\S.*"`
- Modèle de chaîne personnalisée #14 – `"[a-zA-Z0-9-=_./@]+"`
- Modèle de chaîne personnalisée #15 – `"[1-9][0-9]*|[1-9][0-9]*-[1-9][0-9]*"`
- Modèle de chaîne personnalisée #16 – `"[A-Z][A-Za-z\.\.]"`
- Modèle de chaîne personnalisée #17 – `"[\S]*"`
- Modèle de chaîne personnalisée #18 – `"[\w]*"`
- Modèle de chaîne personnalisée #19 – `"arn:aws[a-z\.-]*:iam::\d{12}:role/?[a-zA-Z0-9+/,.@\._/]"`

- Modèle de chaîne personnalisée #20 – "subnet-[a-z0-9]+"
- Modèle de chaîne personnalisée #21 – "\d{12}"
- Modèle de chaîne personnalisée #22 – "([a-z]+)-([a-z]+-)?([a-z]+)-[0-9]+[a-z]+"
- Modèle de chaîne personnalisée #23 – "[a-zA-Z0-9.-]*"
- Modèle de chaîne personnalisée #24 – « arn:aws[a-z0-9\-*]:lambda:[a-z0-9\-*]:\d{12}:function:([\w\-*]{1,64}) »
- Modèle de chaîne personnalisée #25 – « ^(?!(.*[\.\\/\|aws:])).*\$ »
- Modèle de chaîne personnalisée #26 – « [^\r\n] »
- Modèle de chaîne personnalisée #27 – « ^\w+\.\w+\.\w+\$ »
- Modèle de chaîne personnalisée #28 – « ^\w+\.\w+\$ »
- Modèle de chaîne personnalisée #29 – « ^\$|arn:aws[a-z0-9-*]:kms:.* »
- Modèle de chaîne personnalisée #30 – « arn:aws[^:]*:iam::[0-9]*:role/.+ »
- Modèle de chaîne personnalisée #31 – « [\._A-Za-z0-9]+ »
- Modèle de chaîne personnalisée #32 – « ^s3://([^\/*]+)/([^\/*]+)*([^\/*]+)\$ »
- Modèle de chaîne personnalisée #33 – « .* »
- Modèle de chaîne personnalisée #34 – « ^(Sun|Mon|Tue|Wed|Thu|Fri|Sat):([01]?[0-9]|2[0-3])\$ »
- Modèle de chaîne personnalisée n° 35 – « [a-zA-Z0-9_.-]+ »
- Schéma de chaîne personnalisé #36 — « ^arn:aws(-(cn|us-gov|iso(-[bef]))?)?:secretsmanager:.*\$ »
- Schéma de chaîne personnalisé #37 — « \S+ »
- Schéma de chaîne personnalisé #38 — « ^[\x20-\x7E]*\$ »
- Schéma de chaîne personnalisé #39 — « ^([a-zA-Z0-9_]=+)\.([a-zA-Z0-9_]=+)\.([a-zA-Z0-9_-\+\/=]*) »
- Schéma de chaîne personnalisé #40 — « ^(https?):\/\/[-a-zA-Z0-9+&@#/%?~_!|:,.;]*[-a-zA-Z0-9+&@#/%?~_!|] »
- Schéma de chaîne personnalisé #41 — « ^(https?):\.\.\/[^\s/\$.?\#].[\^\s]*\$ »
- Schéma de chaîne personnalisé #42 — « ^subnet-[a-z0-9]+\$ »
- Schéma de chaîne personnalisé #43 — « [\p{L}\p{N}\p{P}]* »
- Schéma de chaîne personnalisé #44 — « [a-f0-9]{8}-[a-f0-9]{4}-[a-f0-9]{4}-[a-f0-9]{4}-[a-f0-9]{12} »

- Schéma de chaîne personnalisée #45 — « `[a-zA-Z0-9-_$#.]+` »
- Schéma de chaîne personnalisée #46 — « `^\d{12}$` »
- Schéma de chaîne personnalisée #47 — « `^(\w+\.)+\w+$` »
- Schéma de chaîne personnalisée #48 — « `^([2-3]|3[.]9)$` »
- Schéma de chaîne personnalisée #49 — « `arn:aws(-(cn|us-gov|iso(-[bef]))?))? :glue:. *` »
- Schéma de chaîne personnalisée #50 — « `(^arn:aws(-(cn|us-gov|iso(-[bef]))?))? :iam::\w{12}:root)` »
- Schéma de chaîne personnalisée #51 — « `^arn:aws(-(cn|us-gov|iso(-[bef]))?))? :iam:: [0-9]{12}:role/.+ »`
- Schéma de chaîne personnalisée #52 — « `[\s\S]*` »
- Schéma de chaîne personnalisée #53 — « `([\u0020-\u007F\uE000-\uFFFF\uD800\uDC00-\uDBFF\uDFFF]|(^\\S\\r\\n"'= ;])* »`
- Schéma de chaîne personnalisée #54 — « `^[A-Z\\_]+$` »
- Schéma de chaîne personnalisée #55 — « `^[A-Za-z0-9]+$` »
- Schéma de chaîne personnalisée #56 — « `[*A-Za-z0-9_-]*` »
- Schéma de chaîne personnalisée #57 — « `([\u0020-\u007E\\r\\s\\n])* »`
- Schéma de chaîne personnalisée #58 — « `[A-Za-z0-9_-]*` »
- Schéma de chaîne personnalisée #59 — « `([\u0009\u000B\u000C\u0020-\u007F\uE000-\uFFFF\uD800\uDC00-\uDBFF\uDFFF])* »`
- Schéma de chaîne personnalisée #60 — « `([\u0020-\u007F\uE000-\uFFFF\uD800\uDC00-\uDBFF\uDFFF\\s])* »`
- Schéma de chaîne personnalisée #61 — « `([^\\r\\n])* »`

Exceptions

Cette section décrit les AWS Glue exceptions que vous pouvez utiliser pour identifier la source des problèmes et les résoudre. Pour plus d'informations sur les chaînes et les codes d'erreur HTTP des exceptions liées au machine learning, consultez [the section called “AWS Glue exceptions relatives à l'apprentissage automatique”](#).

AccessDeniedException structure

L'accès à une ressource a été refusé.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

AlreadyExistsException structure

Une ressource à créer ou à ajouter existe déjà.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

ConcurrentModificationException structure

Deux processus tentent de modifier une ressource simultanément.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

ConcurrentRunsExceededException structure

Un trop grand nombre de tâches sont exécutées simultanément.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

CrawlerNotRunningException structure

L'crawler spécifié n'est pas en cours d'exécution.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

CrawlerRunningException structure

L'opération ne peut pas être effectuée car l'crawler est déjà en cours d'exécution.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

CrawlerStoppingException structure

L'crawler spécifié est en cours d'arrêt.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

EntityNotFoundException structure

Une entité spécifiée n'existe pas.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

- FromFederationSource – Booléen.

Indique si l'exception concerne une source fédérée.

FederationSourceException structure

Une source de fédération a échoué.

Champs

- `FederationSourceErrorCode`— Chaîne UTF-8 (valeurs valides : `AccessDeniedException` | `EntityNotFoundException` | `InvalidCredentialsException` | `InvalidInputException` | `InvalidResponseException` | `OperationTimeoutException` | `OperationNotSupportedException` | `InternalServiceException` | `PartialFailureException` | `ThrottlingException`).

Le code d'erreur du problème.

- `Message` – Chaîne UTF-8.

Un message décrivant le problème.

FederationSourceRetryableException structure

Une source de fédération a échoué, mais l'opération peut être tentée à nouveau.

Champs

- `Message` – Chaîne UTF-8.

Un message décrivant le problème.

GlueEncryptionException structure

Une opération de chiffrement a échoué.

Champs

- `Message` – Chaîne UTF-8.

Un message décrivant le problème.

IdempotentParameterMismatchException structure

Le même identifiant unique a été associé à deux enregistrements différents.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

IllegalWorkflowStateException structure

Le flux de travail est dans un état non valide pour effectuer une opération demandée.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

InternalServiceException structure

Une erreur de service interne s'est produite.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

InvalidExecutionEngineException structure

Un moteur d'exécution inconnu ou non valide a été spécifié.

Champs

- message – Chaîne UTF-8.

Un message décrivant le problème.

InvalidInputException structure

L'entrée fournie n'est pas valide.

Champs

- `Message` – Chaîne UTF-8.

Un message décrivant le problème.

- `FromFederationSource` – Booléen.

Indique si l'exception concerne une source fédérée.

InvalidStateException structure

Une erreur indiquant que vos données sont dans un état non valide.

Champs

- `Message` – Chaîne UTF-8.

Un message décrivant le problème.

InvalidTaskStatusTransitionException structure

Une transition correcte d'une tâche à une autre a échoué.

Champs

- `message` – Chaîne UTF-8.

Un message décrivant le problème.

JobDefinitionErrorException structure

Une définition de tâche n'est pas valide.

Champs

- `message` – Chaîne UTF-8.

Un message décrivant le problème.

JobRunInTerminalStateException structure

L'état de mise hors service d'une exécution de tâche signale une défaillance.

Champs

- message – Chaîne UTF-8.

Un message décrivant le problème.

JobRunInvalidStateTransitionException structure

Une exécution de tâche a rencontré une transition non valide de l'état source vers l'état cible.

Champs

- jobId – Chaîne UTF-8, d'une longueur comprise entre 1 et 255 octets, correspondant au [Single-line string pattern](#).

ID de l'exécution de tâche en question.

- message – Chaîne UTF-8.

Un message décrivant le problème.

- sourceState— Chaîne UTF-8 (valeurs valides : STARTING | RUNNING | STOPPING | STOPPED | SUCCEEDED | FAILED | TIMEOUT ERROR WAITING | EXPIRED).

État source.

- targetState— Chaîne UTF-8 (valeurs valides : STARTING | RUNNING | STOPPING | STOPPED | SUCCEEDED | FAILED | TIMEOUT ERROR WAITING | EXPIRED).

État cible.

JobRunNotInTerminalStateException structure

Une exécution de tâche n'est pas dans un état de mise hors service.

Champs

- message – Chaîne UTF-8.

Un message décrivant le problème.

LateRunnerException structure

Un exécuteur de tâche est en retard.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

NoScheduleException structure

Il n'y a pas de calendrier applicable.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

OperationTimeoutException structure

L'opération a expiré.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

ResourceNotReadyException structure

Une ressource n'était pas prête pour une transaction.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

ResourceNumberLimitExceededException structure

Une limite numérique de ressource a été dépassée.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

SchedulerNotRunningException structure

Le planificateur spécifié n'est pas en cours d'exécution.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

SchedulerRunningException structure

Le planificateur spécifié est déjà en cours d'exécution.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

SchedulerTransitioningException structure

Le planificateur spécifié est en cours de conversion.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

UnrecognizedRunnerException structure

L' exécuter de tâche na pas été reconnu.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

ValidationException structure

Une valeur n'a pas pu être validée.

Champs

- Message – Chaîne UTF-8.

Un message décrivant le problème.

VersionMismatchException structure

Un conflit de version s'est produit.

Champs

- message – Chaîne UTF-8.

Un message décrivant le problème.

AWS Glue Exemples de code d'API utilisant AWS SDKs

Les exemples de code suivants montrent comment utiliser AWS Glue un kit de développement AWS logiciel (SDK).

Les principes de base sont des exemples de code qui vous montrent comment effectuer les opérations essentielles au sein d'un service.

Les actions sont des extraits de code de programmes plus larges et doivent être exécutées dans leur contexte. Alors que les actions vous indiquent comment appeler des fonctions de service individuelles, vous pouvez les voir en contexte dans leurs scénarios associés.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Mise en route

Bonjour AWS Glue

Les exemples de code suivants montrent comment démarrer avec AWS Glue.

.NET

SDK pour .NET

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
namespace GlueActions;

public class HelloGlue
{
    private static ILogger logger = null!;

    static async Task Main(string[] args)
    {
        // Set up dependency injection for AWS Glue.
```



```
using var host = Host.CreateDefaultBuilder(args)
    .ConfigureLogging(logging =>
        logging.AddFilter("System", LogLevel.Debug)
        .AddFilter<DebugLoggerProvider>("Microsoft",
LogLevel.Information)
        .AddFilter<ConsoleLoggerProvider>("Microsoft",
LogLevel.Trace))
    .ConfigureServices((_, services) =>
        services.AddAWSService<IAmazonGlue>()
        .AddTransient<GlueWrapper>()
    )
    .Build();

logger = LoggerFactory.Create(builder => { builder.AddConsole(); })
    .CreateLogger<HelloGlue>();
var glueClient = host.Services.GetRequiredService<IAmazonGlue>();

var request = new ListJobsRequest();

var jobNames = new List<string>();

do
{
    var response = await glueClient.ListJobsAsync(request);
    jobNames.AddRange(response.JobNames);
    request.NextToken = response.NextToken;
}
while (request.NextToken is not null);

Console.Clear();
Console.WriteLine("Hello, Glue. Let's list your existing Glue Jobs:");
if (jobNames.Count == 0)
{
    Console.WriteLine("You don't have any AWS Glue jobs.");
}
else
{
    jobNames.ForEach(Console.WriteLine);
}
}
```

- Pour plus de détails sur l'API, reportez-vous [ListJobs](#) à la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

Code pour le CMake fichier CMake Lists.txt.

```
# Set the minimum required version of CMake for this project.
cmake_minimum_required(VERSION 3.13)

# Set the AWS service components used by this project.
set(SERVICE_COMPONENTS glue)

# Set this project's name.
project("hello_glue")

# Set the C++ standard to use to build this target.
# At least C++ 11 is required for the AWS SDK for C++.
set(CMAKE_CXX_STANDARD 11)

# Use the MSVC variable to determine if this is a Windows build.
set(WINDOWS_BUILD ${MSVC})

if (WINDOWS_BUILD) # Set the location where CMake can find the installed
  libraries for the AWS SDK.
    string(REPLACE ";" "/aws-cpp-sdk-all;" SYSTEM_MODULE_PATH
      "${CMAKE_SYSTEM_PREFIX_PATH}/aws-cpp-sdk-all")
    list(APPEND CMAKE_PREFIX_PATH ${SYSTEM_MODULE_PATH})
  endif ()

# Find the AWS SDK for C++ package.
find_package(AWSSDK REQUIRED COMPONENTS ${SERVICE_COMPONENTS})

if (WINDOWS_BUILD AND AWSSDK_INSTALL_AS_SHARED_LIBS)
```

```

    # Copy relevant AWS SDK for C++ libraries into the current binary directory
    for running and debugging.

    # set(BIN_SUB_DIR "/Debug") # if you are building from the command line you
    may need to uncomment this

                                # and set the proper subdirectory to the
    executables' location.

    AWSSDK_CPY_DYN_LIBS(SERVICE_COMPONENTS ""
    ${CMAKE_CURRENT_BINARY_DIR}${BIN_SUB_DIR})
endif ()

add_executable(${PROJECT_NAME}
    hello_glue.cpp)

target_link_libraries(${PROJECT_NAME}
    ${AWSSDK_LINK_LIBRARIES})

```

Code pour le fichier source hello_glue.cpp.

```

#include <aws/core/Aws.h>
#include <aws/glue/GlueClient.h>
#include <aws/glue/model/ListJobsRequest.h>
#include <iostream>

/*
 * A "Hello Glue" starter application which initializes an AWS Glue client and
 * lists the
 * AWS Glue job definitions.
 *
 * main function
 *
 * Usage: 'hello_glue'
 */

int main(int argc, char **argv) {
    Aws::SDKOptions options;
    // Optionally change the log level for debugging.
    // options.loggingOptions.logLevel = Utils::Logging::LogLevel::Debug;
    Aws::InitAPI(options); // Should only be called once.
    int result = 0;

```

```

{
    Aws::Client::ClientConfiguration clientConfig;
    // Optional: Set to the AWS Region (overrides config file).
    // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient glueClient(clientConfig);

    std::vector<Aws::String> jobs;

    Aws::String nextToken; // Used for pagination.
    do {
        Aws::Glue::Model::ListJobsRequest listJobsRequest;
        if (!nextToken.empty()) {
            listJobsRequest.SetNextToken(nextToken);
        }

        Aws::Glue::Model::ListJobsOutcome listRunsOutcome =
glueClient.ListJobs(
            listJobsRequest);

        if (listRunsOutcome.IsSuccess()) {
            const std::vector<Aws::String> &jobNames =
listRunsOutcome.GetResult().GetJobNames();
            jobs.insert(jobs.end(), jobNames.begin(), jobNames.end());

            nextToken = listRunsOutcome.GetResult().GetNextToken();
        } else {
            std::cerr << "Error listing jobs. "
                << listRunsOutcome.GetError().GetMessage()
                << std::endl;
            result = 1;
            break;
        }
    } while (!nextToken.empty());

    std::cout << "Your account has " << jobs.size() << " jobs."
        << std::endl;
    for (size_t i = 0; i < jobs.size(); ++i) {
        std::cout << "    " << i + 1 << ". " << jobs[i] << std::endl;
    }
}

Aws::ShutdownAPI(options); // Should only be called once.
return result;
}

```

- Pour plus de détails sur l'API, reportez-vous [ListJobs](#) à la section Référence des AWS SDK pour C++ API.

Java

SDK pour Java 2.x

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
package com.example.glue;

import software.amazon.awssdk.regions.Region;
import software.amazon.awssdk.services.glue.GlueClient;
import software.amazon.awssdk.services.glue.model.ListJobsRequest;
import software.amazon.awssdk.services.glue.model.ListJobsResponse;
import java.util.List;

public class HelloGlue {
    public static void main(String[] args) {
        GlueClient glueClient = GlueClient.builder()
            .region(Region.US_EAST_1)
            .build();

        listJobs(glueClient);
    }

    public static void listJobs(GlueClient glueClient) {
        ListJobsRequest request = ListJobsRequest.builder()
            .maxResults(10)
            .build();
        ListJobsResponse response = glueClient.listJobs(request);
        List<String> jobList = response.jobNames();
        jobList.forEach(job -> {
            System.out.println("Job Name: " + job);
        });
    }
}
```

```
}  
}
```

- Pour plus de détails sur l'API, reportez-vous [ListJobs](#) à la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
import { ListJobsCommand, GlueClient } from "@aws-sdk/client-glue";  
  
const client = new GlueClient({});  
  
export const main = async () => {  
  const command = new ListJobsCommand({});  
  
  const { JobNames } = await client.send(command);  
  const formattedJobNames = JobNames.join("\n");  
  console.log("Job names: ");  
  console.log(formattedJobNames);  
  return JobNames;  
};
```

- Pour plus de détails sur l'API, reportez-vous [ListJobs](#) à la section Référence des AWS SDK pour JavaScript API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
import boto3
from botocore.exceptions import ClientError

def hello_glue():
    """
    Lists the job definitions in your AWS Glue account, using the AWS SDK for
    Python (Boto3).
    """
    try:
        # Create the Glue client
        glue = boto3.client("glue")

        # List the jobs, limiting the results to 10 per page
        paginator = glue.get_paginator("get_jobs")
        response_iterator = paginator.paginate(
            PaginationConfig={"MaxItems": 10, "PageSize": 10}
        )

        # Print the job names
        print("Here are the jobs in your account:")
        for page in response_iterator:
            for job in page["Jobs"]:
                print(f"\t{job['Name']}")

    except ClientError as e:
        print(f"Error: {e}")

if __name__ == "__main__":
    hello_glue()
```

- Pour plus de détails sur l'API, consultez [ListJobs](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
require 'aws-sdk-glue'
require 'logger'

# GlueManager is a class responsible for managing AWS Glue operations
# such as listing all Glue jobs in the current AWS account.
class GlueManager
  def initialize(client)
    @client = client
    @logger = Logger.new($stdout)
  end

  # Lists and prints all Glue jobs in the current AWS account.
  def list_jobs
    @logger.info('Here are the Glue jobs in your account:')

    paginator = @client.get_jobs(max_results: 10)
    jobs = []

    paginator.each_page do |page|
      jobs.concat(page.jobs)
    end

    if jobs.empty?
      @logger.info("You don't have any Glue jobs.")
    end
  end
end
```



```

    else
      jobs.each do |job|
        @logger.info("- #{job.name}")
      end
    end
  end
end

if $PROGRAM_NAME == __FILE__
  glue_client = Aws::Glue::Client.new
  manager = GlueManager.new(glue_client)
  manager.list_jobs
end

```

- Pour plus de détails sur l'API, reportez-vous [ListJobs](#) à la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

let mut list_jobs = glue.list_jobs().into_paginator().send();
while let Some(list_jobs_output) = list_jobs.next().await {
  match list_jobs_output {
    Ok(list_jobs) => {
      let names = list_jobs.job_names();
      info!(?names, "Found these jobs")
    }
    Err(err) => return Err(GlueMvpError::from_glue_sdk(err)),
  }
}

```

- Pour plus de détails sur l'API, voir [ListJobs](#) la section de référence de l'API AWS SDK for Rust.

AWS Glue Exemples de code d'API

- [Exemples de base pour AWS Glue l'utilisation AWS SDKs](#)
 - [Bonjour AWS Glue](#)
 - [Apprenez les bases AWS Glue d'un AWS SDK](#)
 - [Actions d' AWS Glue utilisation AWS SDKs](#)
 - [Utilisation CreateCrawler avec un AWS SDK](#)
 - [Utilisation CreateJob avec un AWS SDK ou une CLI](#)
 - [Utilisation DeleteCrawler avec un AWS SDK](#)
 - [Utilisation DeleteDatabase avec un AWS SDK](#)
 - [Utilisation DeleteJob avec un AWS SDK ou une CLI](#)
 - [Utilisation DeleteTable avec un AWS SDK](#)
 - [Utilisation GetCrawler avec un AWS SDK](#)
 - [Utilisation GetDatabase avec un AWS SDK](#)
 - [Utilisation GetDatabases avec un AWS SDK ou une CLI](#)
 - [Utilisation GetJob avec un AWS SDK ou une CLI](#)
 - [Utilisation GetJobRun avec un AWS SDK ou une CLI](#)
 - [Utilisation GetJobRuns avec un AWS SDK ou une CLI](#)
 - [Utilisation GetTables avec un AWS SDK ou une CLI](#)
 - [Utilisation ListJobs avec un AWS SDK](#)
 - [Utilisation StartCrawler avec un AWS SDK ou une CLI](#)
 - [Utilisation StartJobRun avec un AWS SDK ou une CLI](#)

Exemples de base pour AWS Glue l'utilisation AWS SDKs

Les exemples de code suivants montrent comment utiliser les principes de base de AWS Glue with AWS SDKs.

Exemples

- [Bonjour AWS Glue](#)

- [Apprenez les bases AWS Glue d'un AWS SDK](#)
- [Actions d' AWS Glue utilisation AWS SDKs](#)
 - [Utilisation CreateCrawler avec un AWS SDK](#)
 - [Utilisation CreateJob avec un AWS SDK ou une CLI](#)
 - [Utilisation DeleteCrawler avec un AWS SDK](#)
 - [Utilisation DeleteDatabase avec un AWS SDK](#)
 - [Utilisation DeleteJob avec un AWS SDK ou une CLI](#)
 - [Utilisation DeleteTable avec un AWS SDK](#)
 - [Utilisation GetCrawler avec un AWS SDK](#)
 - [Utilisation GetDatabase avec un AWS SDK](#)
 - [Utilisation GetDatabases avec un AWS SDK ou une CLI](#)
 - [Utilisation GetJob avec un AWS SDK ou une CLI](#)
 - [Utilisation GetJobRun avec un AWS SDK ou une CLI](#)
 - [Utilisation GetJobRuns avec un AWS SDK ou une CLI](#)
 - [Utilisation GetTables avec un AWS SDK ou une CLI](#)
 - [Utilisation ListJobs avec un AWS SDK](#)
 - [Utilisation StartCrawler avec un AWS SDK ou une CLI](#)
 - [Utilisation StartJobRun avec un AWS SDK ou une CLI](#)

Bonjour AWS Glue

Les exemples de code suivants montrent comment démarrer avec AWS Glue.

.NET

SDK pour .NET

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
namespace GlueActions;
```

```
public class HelloGlue
{
    private static ILogger logger = null!;

    static async Task Main(string[] args)
    {
        // Set up dependency injection for AWS Glue.
        using var host = Host.CreateDefaultBuilder(args)
            .ConfigureLogging(logging =>
                logging.AddFilter("System", LogLevel.Debug)
                    .AddFilter<DebugLoggerProvider>("Microsoft",
                        LogLevel.Information)
                    .AddFilter<ConsoleLoggerProvider>("Microsoft",
                        LogLevel.Trace))
            .ConfigureServices((_, services) =>
                services.AddAWSService<IAmazonGlue>()
                    .AddTransient<GlueWrapper>()
            )
            .Build();

        logger = LoggerFactory.Create(builder => { builder.AddConsole(); })
            .CreateLogger<HelloGlue>();
        var glueClient = host.Services.GetRequiredService<IAmazonGlue>();

        var request = new ListJobsRequest();

        var jobNames = new List<string>();

        do
        {
            var response = await glueClient.ListJobsAsync(request);
            jobNames.AddRange(response.JobNames);
            request.NextToken = response.NextToken;
        }
        while (request.NextToken is not null);

        Console.Clear();
        Console.WriteLine("Hello, Glue. Let's list your existing Glue Jobs:");
        if (jobNames.Count == 0)
        {
            Console.WriteLine("You don't have any AWS Glue jobs.");
        }
        else
    }
```

```
        {  
            jobNames.ForEach(Console.WriteLine);  
        }  
    }  
}
```

- Pour plus de détails sur l'API, reportez-vous [ListJobs](#) à la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

Code pour le CMake fichier CMake Lists.txt.

```
# Set the minimum required version of CMake for this project.  
cmake_minimum_required(VERSION 3.13)  
  
# Set the AWS service components used by this project.  
set(SERVICE_COMPONENTS glue)  
  
# Set this project's name.  
project("hello_glue")  
  
# Set the C++ standard to use to build this target.  
# At least C++ 11 is required for the AWS SDK for C++.  
set(CMAKE_CXX_STANDARD 11)  
  
# Use the MSVC variable to determine if this is a Windows build.  
set(WINDOWS_BUILD ${MSVC})  
  
if (WINDOWS_BUILD) # Set the location where CMake can find the installed  
    libraries for the AWS SDK.
```

```

    string(REPLACE ";" "/aws-cpp-sdk-all;" SYSTEM_MODULE_PATH
"${CMAKE_SYSTEM_PREFIX_PATH}/aws-cpp-sdk-all")
    list(APPEND CMAKE_PREFIX_PATH ${SYSTEM_MODULE_PATH})
endif ()

# Find the AWS SDK for C++ package.
find_package(AWSSDK REQUIRED COMPONENTS ${SERVICE_COMPONENTS})

if (WINDOWS_BUILD AND AWSSDK_INSTALL_AS_SHARED_LIBS)
    # Copy relevant AWS SDK for C++ libraries into the current binary directory
    for running and debugging.

    # set(BIN_SUB_DIR "/Debug") # if you are building from the command line you
    may need to uncomment this

                                # and set the proper subdirectory to the
    executables' location.

    AWSSDK_CPY_DYN_LIBS(SERVICE_COMPONENTS ""
"${CMAKE_CURRENT_BINARY_DIR}${BIN_SUB_DIR}")
endif ()

add_executable(${PROJECT_NAME}
    hello_glue.cpp)

target_link_libraries(${PROJECT_NAME}
    ${AWSSDK_LINK_LIBRARIES})

```

Code pour le fichier source hello_glue.cpp.

```

#include <aws/core/Aws.h>
#include <aws/glue/GlueClient.h>
#include <aws/glue/model/ListJobsRequest.h>
#include <iostream>

/*
 * A "Hello Glue" starter application which initializes an AWS Glue client and
 * lists the
 * AWS Glue job definitions.
 *
 * main function
 *
 * Usage: 'hello_glue'
 */

```

```

*
*/

int main(int argc, char **argv) {
    Aws::SDKOptions options;
    // Optionally change the log level for debugging.
    // options.loggingOptions.logLevel = Utils::Logging::LogLevel::Debug;
    Aws::InitAPI(options); // Should only be called once.
    int result = 0;
    {
        Aws::Client::ClientConfiguration clientConfig;
        // Optional: Set to the AWS Region (overrides config file).
        // clientConfig.region = "us-east-1";

        Aws::Glue::GlueClient glueClient(clientConfig);

        std::vector<Aws::String> jobs;

        Aws::String nextToken; // Used for pagination.
        do {
            Aws::Glue::Model::ListJobsRequest listJobsRequest;
            if (!nextToken.empty()) {
                listJobsRequest.SetNextToken(nextToken);
            }

            Aws::Glue::Model::ListJobsOutcome listRunsOutcome =
glueClient.ListJobs(
                listJobsRequest);

            if (listRunsOutcome.IsSuccess()) {
                const std::vector<Aws::String> &jobNames =
listRunsOutcome.GetResult().GetJobNames();
                jobs.insert(jobs.end(), jobNames.begin(), jobNames.end());

                nextToken = listRunsOutcome.GetResult().GetNextToken();
            } else {
                std::cerr << "Error listing jobs. "
                    << listRunsOutcome.GetError().GetMessage()
                    << std::endl;
                result = 1;
                break;
            }
        } while (!nextToken.empty());
    }
}

```

```

        std::cout << "Your account has " << jobs.size() << " jobs."
            << std::endl;
        for (size_t i = 0; i < jobs.size(); ++i) {
            std::cout << "    " << i + 1 << ". " << jobs[i] << std::endl;
        }
    }
    Aws::ShutdownAPI(options); // Should only be called once.
    return result;
}

```

- Pour plus de détails sur l'API, reportez-vous [ListJobs](#) à la section Référence des AWS SDK pour C++ API.

Java

SDK pour Java 2.x

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

package com.example.glue;

import software.amazon.awssdk.regions.Region;
import software.amazon.awssdk.services.glue.GlueClient;
import software.amazon.awssdk.services.glue.model.ListJobsRequest;
import software.amazon.awssdk.services.glue.model.ListJobsResponse;
import java.util.List;

public class HelloGlue {
    public static void main(String[] args) {
        GlueClient glueClient = GlueClient.builder()
            .region(Region.US_EAST_1)
            .build();

        listJobs(glueClient);
    }
}

```



```
public static void listJobs(GlueClient glueClient) {
    ListJobsRequest request = ListJobsRequest.builder()
        .maxResults(10)
        .build();
    ListJobsResponse response = glueClient.listJobs(request);
    List<String> jobList = response.jobNames();
    jobList.forEach(job -> {
        System.out.println("Job Name: " + job);
    });
}
```

- Pour plus de détails sur l'API, reportez-vous [ListJobs](#) à la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
import { ListJobsCommand, GlueClient } from "@aws-sdk/client-glue";

const client = new GlueClient({});

export const main = async () => {
    const command = new ListJobsCommand({});

    const { JobNames } = await client.send(command);
    const formattedJobNames = JobNames.join("\n");
    console.log("Job names: ");
    console.log(formattedJobNames);
    return JobNames;
};
```

- Pour plus de détails sur l'API, reportez-vous [ListJobs](#) à la section Référence des AWS SDK pour JavaScript API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
import boto3
from botocore.exceptions import ClientError

def hello_glue():
    """
    Lists the job definitions in your AWS Glue account, using the AWS SDK for
    Python (Boto3).
    """
    try:
        # Create the Glue client
        glue = boto3.client("glue")

        # List the jobs, limiting the results to 10 per page
        paginator = glue.get_paginator("get_jobs")
        response_iterator = paginator.paginate(
            PaginationConfig={"MaxItems": 10, "PageSize": 10}
        )

        # Print the job names
        print("Here are the jobs in your account:")
        for page in response_iterator:
            for job in page["Jobs"]:
                print(f"\t{job['Name']}")

    except ClientError as e:
        print(f"Error: {e}")
```

```
if __name__ == "__main__":  
    hello_glue()
```

- Pour plus de détails sur l'API, consultez [ListJobs](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
require 'aws-sdk-glue'  
require 'logger'  
  
# GlueManager is a class responsible for managing AWS Glue operations  
# such as listing all Glue jobs in the current AWS account.  
class GlueManager  
  def initialize(client)  
    @client = client  
    @logger = Logger.new($stdout)  
  end  
  
  # Lists and prints all Glue jobs in the current AWS account.  
  def list_jobs  
    @logger.info('Here are the Glue jobs in your account:')  
  
    paginator = @client.get_jobs(max_results: 10)  
    jobs = []  
  
    paginator.each_page do |page|  
      jobs.concat(page.jobs)  
    end  
  end  
end
```

```

end

if jobs.empty?
  @logger.info("You don't have any Glue jobs.")
else
  jobs.each do |job|
    @logger.info("- #{job.name}")
  end
end
end
end

if $PROGRAM_NAME == __FILE__
  glue_client = Aws::Glue::Client.new
  manager = GlueManager.new(glue_client)
  manager.list_jobs
end

```

- Pour plus de détails sur l'API, reportez-vous [ListJobs](#) à la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

let mut list_jobs = glue.list_jobs().into_paginator().send();
while let Some(list_jobs_output) = list_jobs.next().await {
  match list_jobs_output {
    Ok(list_jobs) => {
      let names = list_jobs.job_names();
      info!(?names, "Found these jobs")
    }
    Err(err) => return Err(GlueMvpError::from_glue_sdk(err)),
  }
}

```

```
}  
}
```

- Pour plus de détails sur l'API, voir [ListJobs](#) la section de référence de l'API AWS SDK for Rust.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Apprenez les bases AWS Glue d'un AWS SDK

Les exemples de code suivants montrent comment :

- Créez un Crawler qui indexe un compartiment Amazon S3 public et génère une base de données de métadonnées au format CSV.
- Répertoriez les informations relatives aux bases de données et aux tables de votre AWS Glue Data Catalog.
- Créez une tâche pour extraire les données CSV du compartiment S3, transformer les données et charger la sortie au format JSON dans un autre compartiment S3.
- Répertoriez les informations relatives aux exécutions de tâches, visualisez les données transformées et nettoyez les ressources.

Pour plus d'informations, consultez [Tutoriel : prise en main de AWS Glue Studio](#).

.NET

SDK pour .NET

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

Créez une classe qui englobe les AWS Glue fonctions utilisées dans le scénario.

```
using System.Net;

namespace GlueActions;

public class GlueWrapper
{
    private readonly IAmazonGlue _amazonGlue;

    /// <summary>
    /// Constructor for the AWS Glue actions wrapper.
    /// </summary>
    /// <param name="amazonGlue"></param>
    public GlueWrapper(IAmazonGlue amazonGlue)
    {
        _amazonGlue = amazonGlue;
    }

    /// <summary>
    /// Create an AWS Glue crawler.
    /// </summary>
    /// <param name="crawlerName">The name for the crawler.</param>
    /// <param name="crawlerDescription">A description of the crawler.</param>
    /// <param name="role">The AWS Identity and Access Management (IAM) role to
    /// be assumed by the crawler.</param>
    /// <param name="schedule">The schedule on which the crawler will be
    /// executed.</param>
    /// <param name="s3Path">The path to the Amazon Simple Storage Service
    /// (Amazon S3)
    /// bucket where the Python script has been stored.</param>
    /// <param name="dbName">The name to use for the database that will be
    /// created by the crawler.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> CreateCrawlerAsync(
        string crawlerName,
        string crawlerDescription,
        string role,
        string schedule,
        string s3Path,
        string dbName)
    {
        var s3Target = new S3Target
        {
```

```

        Path = s3Path,
    };

    var targetList = new List<S3Target>
    {
        s3Target,
    };

    var targets = new CrawlerTargets
    {
        S3Targets = targetList,
    };

    var crawlerRequest = new CreateCrawlerRequest
    {
        DatabaseName = dbName,
        Name = crawlerName,
        Description = crawlerDescription,
        Targets = targets,
        Role = role,
        Schedule = schedule,
    };

    var response = await _amazonGlue.CreateCrawlerAsync(crawlerRequest);
    return response.HttpStatusCode == System.Net.HttpStatusCode.OK;
}

/// <summary>
/// Create an AWS Glue job.
/// </summary>
/// <param name="jobName">The name of the job.</param>
/// <param name="roleName">The name of the IAM role to be assumed by
/// the job.</param>
/// <param name="description">A description of the job.</param>
/// <param name="scriptUrl">The URL to the script.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> CreateJobAsync(string dbName, string tableName,
string bucketUrl, string jobName, string roleName, string description, string
scriptUrl)
{
    var command = new JobCommand
    {
        PythonVersion = "3",

```

```

        Name = "glueetl",
        ScriptLocation = scriptUrl,
    };

    var arguments = new Dictionary<string, string>
    {
        { "--input_database", dbName },
        { "--input_table", tableName },
        { "--output_bucket_url", bucketUrl }
    };

    var request = new CreateJobRequest
    {
        Command = command,
        DefaultArguments = arguments,
        Description = description,
        GlueVersion = "3.0",
        Name = jobName,
        NumberOfWorkers = 10,
        Role = roleName,
        WorkerType = "G.1X"
    };

    var response = await _amazonGlue.CreateJobAsync(request);
    return response.HttpStatusCode == HttpStatusCode.OK;
}

/// <summary>
/// Delete an AWS Glue crawler.
/// </summary>
/// <param name="crawlerName">The name of the crawler.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> DeleteCrawlerAsync(string crawlerName)
{
    var response = await _amazonGlue.DeleteCrawlerAsync(new
DeleteCrawlerRequest { Name = crawlerName });
    return response.HttpStatusCode == HttpStatusCode.OK;
}

/// <summary>
/// Delete the AWS Glue database.
/// </summary>

```



```
/// <param name="dbName">The name of the database.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> DeleteDatabaseAsync(string dbName)
{
    var response = await _amazonGlue.DeleteDatabaseAsync(new
DeleteDatabaseRequest { Name = dbName });
    return response.HttpStatusCode == HttpStatusCode.OK;
}

/// <summary>
/// Delete an AWS Glue job.
/// </summary>
/// <param name="jobName">The name of the job.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> DeleteJobAsync(string jobName)
{
    var response = await _amazonGlue.DeleteJobAsync(new DeleteJobRequest
{ JobName = jobName });
    return response.HttpStatusCode == HttpStatusCode.OK;
}

/// <summary>
/// Delete a table from an AWS Glue database.
/// </summary>
/// <param name="tableName">The table to delete.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> DeleteTableAsync(string dbName, string tableName)
{
    var response = await _amazonGlue.DeleteTableAsync(new DeleteTableRequest
{ Name = tableName, DatabaseName = dbName });
    return response.HttpStatusCode == HttpStatusCode.OK;
}

/// <summary>
/// Get information about an AWS Glue crawler.
/// </summary>
/// <param name="crawlerName">The name of the crawler.</param>
/// <returns>A Crawler object describing the crawler.</returns>
public async Task<Crawler?> GetCrawlerAsync(string crawlerName)
{
    var crawlerRequest = new GetCrawlerRequest
```

```

        {
            Name = crawlerName,
        };

        var response = await _amazonGlue.GetCrawlerAsync(crawlerRequest);
        if (response.HttpStatusCode == System.Net.HttpStatusCode.OK)
        {
            var databaseName = response.Crawler.DatabaseName;
            Console.WriteLine($"{crawlerName} has the database {databaseName}");
            return response.Crawler;
        }

        Console.WriteLine($"No information regarding {crawlerName} could be found.");
        return null;
    }

    /// <summary>
    /// Get information about the state of an AWS Glue crawler.
    /// </summary>
    /// <param name="crawlerName">The name of the crawler.</param>
    /// <returns>A value describing the state of the crawler.</returns>
    public async Task<CrawlerState> GetCrawlerStateAsync(string crawlerName)
    {
        var response = await _amazonGlue.GetCrawlerAsync(
            new GetCrawlerRequest { Name = crawlerName });
        return response.Crawler.State;
    }

    /// <summary>
    /// Get information about an AWS Glue database.
    /// </summary>
    /// <param name="dbName">The name of the database.</param>
    /// <returns>A Database object containing information about the database.</
returns>
    public async Task<Database> GetDatabaseAsync(string dbName)
    {
        var databasesRequest = new GetDatabaseRequest
        {
            Name = dbName,
        };
    }

```

```
        var response = await _amazonGlue.GetDatabaseAsync(databasesRequest);
        return response.Database;
    }

    /// <summary>
    /// Get information about a specific AWS Glue job run.
    /// </summary>
    /// <param name="jobName">The name of the job.</param>
    /// <param name="jobRunId">The Id of the job run.</param>
    /// <returns>A JobRun object with information about the job run.</returns>
    public async Task<JobRun> GetJobRunAsync(string jobName, string jobRunId)
    {
        var response = await _amazonGlue.GetJobRunAsync(new GetJobRunRequest
        { JobName = jobName, RunId = jobRunId });
        return response.JobRun;
    }

    /// <summary>
    /// Get information about all AWS Glue runs of a specific job.
    /// </summary>
    /// <param name="jobName">The name of the job.</param>
    /// <returns>A list of JobRun objects.</returns>
    public async Task<List<JobRun>> GetJobRunsAsync(string jobName)
    {
        var jobRuns = new List<JobRun>();

        var request = new GetJobRunsRequest
        {
            JobName = jobName,
        };

        // No need to loop to get all the log groups--the SDK does it for us
        // behind the scenes
        var paginatorForJobRuns =
            _amazonGlue.Paginators.GetJobRuns(request);

        await foreach (var response in paginatorForJobRuns.Responses)
        {
            response.JobRuns.ForEach(jobRun =>
            {
                jobRuns.Add(jobRun);
            });
        }
    }
}
```

```
    }

    return jobRuns;
}

/// <summary>
/// Get a list of tables for an AWS Glue database.
/// </summary>
/// <param name="dbName">The name of the database.</param>
/// <returns>A list of Table objects.</returns>
public async Task<List<Table>> GetTablesAsync(string dbName)
{
    var request = new GetTablesRequest { DatabaseName = dbName };
    var tables = new List<Table>();

    // Get a paginator for listing the tables.
    var tablePaginator = _amazonGlue.Paginators.GetTables(request);

    await foreach (var response in tablePaginator.Responses)
    {
        tables.AddRange(response.TableList);
    }

    return tables;
}

/// <summary>
/// List AWS Glue jobs using a paginator.
/// </summary>
/// <returns>A list of AWS Glue job names.</returns>
public async Task<List<string>> ListJobsAsync()
{
    var jobNames = new List<string>();

    var listJobsPaginator = _amazonGlue.Paginators.ListJobs(new
ListJobsRequest { MaxResults = 10 });
    await foreach (var response in listJobsPaginator.Responses)
    {
        jobNames.AddRange(response.JobNames);
    }

    return jobNames;
}
```

```
}

/// <summary>
/// Start an AWS Glue crawler.
/// </summary>
/// <param name="crawlerName">The name of the crawler.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> StartCrawlerAsync(string crawlerName)
{
    var crawlerRequest = new StartCrawlerRequest
    {
        Name = crawlerName,
    };

    var response = await _amazonGlue.StartCrawlerAsync(crawlerRequest);

    return response.HttpStatusCode == System.Net.HttpStatusCode.OK;
}

/// <summary>
/// Start an AWS Glue job run.
/// </summary>
/// <param name="jobName">The name of the job.</param>
/// <returns>A string representing the job run Id.</returns>
public async Task<string> StartJobRunAsync(
    string jobName,
    string inputDatabase,
    string inputTable,
    string bucketName)
{
    var request = new StartJobRunRequest
    {
        JobName = jobName,
        Arguments = new Dictionary<string, string>
        {
            {"--input_database", inputDatabase},
            {"--input_table", inputTable},
            {"--output_bucket_url", $"s3://{bucketName}/"}
        }
    };

    var response = await _amazonGlue.StartJobRunAsync(request);
}
```

```
        return response.JobRunId;
    }

}
```

Créez une classe qui exécute le scénario.

```
global using Amazon.Glue;
global using GlueActions;
global using Microsoft.Extensions.Configuration;
global using Microsoft.Extensions.DependencyInjection;
global using Microsoft.Extensions.Hosting;
global using Microsoft.Extensions.Logging;
global using Microsoft.Extensions.Logging.Console;
global using Microsoft.Extensions.Logging.Debug;

using Amazon.Glue.Model;
using Amazon.S3;
using Amazon.S3.Model;

namespace GlueBasics;

public class GlueBasics
{
    private static ILogger logger = null!;
    private static IConfiguration _configuration = null!;

    static async Task Main(string[] args)
    {
        // Set up dependency injection for AWS Glue.
        using var host = Host.CreateDefaultBuilder(args)
            .ConfigureLogging(logging =>
                logging.AddFilter("System", LogLevel.Debug)
                    .AddFilter<DebugLoggerProvider>("Microsoft",
                        LogLevel.Information)
                    .AddFilter<ConsoleLoggerProvider>("Microsoft",
                        LogLevel.Trace))
            .ConfigureServices((_, services) =>
                services.AddAWSService<IAmazonGlue>())
```

```
.AddTransient<GlueWrapper>()
.AddTransient<UiWrapper>()
)
.Build();

logger = LoggerFactory.Create(builder => { builder.AddConsole(); })
.CreateLogger<GlueBasics>();

_configuration = new ConfigurationBuilder()
    .SetBasePath(Directory.GetCurrentDirectory())
    .AddJsonFile("settings.json") // Load settings from .json file.
    .AddJsonFile("settings.local.json",
        true) // Optionally load local settings.
    .Build();

// These values are stored in settings.json
// Once you have run the CDK script to deploy the resources,
// edit the file to set "BucketName", "RoleName", and "ScriptURL"
// to the appropriate values. Also set "CrawlerName" to the name
// you want to give the crawler when it is created.
string bucketName = _configuration["BucketName"]!;
string bucketUrl = _configuration["BucketUrl"]!;
string crawlerName = _configuration["CrawlerName"]!;
string roleName = _configuration["RoleName"]!;
string sourceData = _configuration["SourceData"]!;
string dbName = _configuration["DbName"]!;
string cron = _configuration["Cron"]!;
string scriptUrl = _configuration["ScriptURL"]!;
string jobName = _configuration["JobName"]!;

var wrapper = host.Services.GetRequiredService<GlueWrapper>();
var uiWrapper = host.Services.GetRequiredService<UiWrapper>();

uiWrapper.DisplayOverview();
uiWrapper.PressEnter();

// Create the crawler and wait for it to be ready.
uiWrapper.DisplayTitle("Create AWS Glue crawler");
Console.WriteLine("Let's begin by creating the AWS Glue crawler.");

var crawlerDescription = "Crawler created for the AWS Glue Basics
scenario.";
var crawlerCreated = await wrapper.CreateCrawlerAsync(crawlerName,
crawlerDescription, roleName, cron, sourceData, dbName);
```

```
        if (crawlerCreated)
        {
            Console.WriteLine($"The crawler: {crawlerName} has been created. Now
let's wait until it's ready.");
            CrawlerState crawlerState;
            do
            {
                crawlerState = await wrapper.GetCrawlerStateAsync(crawlerName);
            }
            while (crawlerState != "READY");
            Console.WriteLine($"The crawler {crawlerName} is now ready for
use.");
        }
        else
        {
            Console.WriteLine($"Couldn't create crawler {crawlerName}.");
            return; // Exit the application.
        }

        uiWrapper.DisplayTitle("Start AWS Glue crawler");
        Console.WriteLine("Now let's wait until the crawler has successfully
started.");
        var crawlerStarted = await wrapper.StartCrawlerAsync(crawlerName);
        if (crawlerStarted)
        {
            CrawlerState crawlerState;
            do
            {
                crawlerState = await wrapper.GetCrawlerStateAsync(crawlerName);
            }
            while (crawlerState != "READY");
            Console.WriteLine($"The crawler {crawlerName} is now ready for
use.");
        }
        else
        {
            Console.WriteLine($"Couldn't start the crawler {crawlerName}.");
            return; // Exit the application.
        }

        uiWrapper.PressEnter();

        Console.WriteLine($"\\nLet's take a look at the database: {dbName}");
        var database = await wrapper.GetDatabaseAsync(dbName);
```



```
        if (database != null)
        {
            uiWrapper.DisplayTitle($"{database.Name} Details");
            Console.WriteLine($"{database.Name} created on
{database.CreateTime}");
            Console.WriteLine(database.Description);
        }

        uiWrapper.PressEnter();

        var tables = await wrapper.GetTablesAsync(dbName);
        if (tables.Count > 0)
        {
            tables.ForEach(table =>
            {
                Console.WriteLine($"{table.Name}\tCreated:
{table.CreateTime}\tUpdated: {table.UpdateTime}");
            });
        }

        uiWrapper.PressEnter();

        uiWrapper.DisplayTitle("Create AWS Glue job");
        Console.WriteLine("Creating a new AWS Glue job.");
        var description = "An AWS Glue job created using the AWS SDK for .NET";
        await wrapper.CreateJobAsync(dbName, tables[0].Name, bucketUrl, jobName,
roleName, description, scriptUrl);

        uiWrapper.PressEnter();

        uiWrapper.DisplayTitle("Starting AWS Glue job");
        Console.WriteLine("Starting the new AWS Glue job...");
        var jobRunId = await wrapper.StartJobRunAsync(jobName, dbName,
tables[0].Name, bucketName);
        var jobRunComplete = false;
        var jobRun = new JobRun();
        do
        {
            jobRun = await wrapper.GetJobRunAsync(jobName, jobRunId);
            if (jobRun.JobRunState == "SUCCEEDED" || jobRun.JobRunState ==
"STOPPED" ||
                jobRun.JobRunState == "FAILED" || jobRun.JobRunState ==
"TIMEOUT")
```

```
        {
            jobRunComplete = true;
        }
    } while (!jobRunComplete);

    uiWrapper.DisplayTitle($"Data in {bucketName}");

    // Get the list of data stored in the S3 bucket.
    var s3Client = new AmazonS3Client();

    var response = await s3Client.ListObjectsAsync(new ListObjectsRequest
{ BucketName = bucketName });
    response.S3Objects.ForEach(s3Object =>
    {
        Console.WriteLine(s3Object.Key);
    });

    uiWrapper.DisplayTitle("AWS Glue jobs");
    var jobNames = await wrapper.ListJobsAsync();
    jobNames.ForEach(jobName =>
    {
        Console.WriteLine(jobName);
    });

    uiWrapper.PressEnter();

    uiWrapper.DisplayTitle("Get AWS Glue job run information");
    Console.WriteLine("Getting information about the AWS Glue job.");
    var jobRuns = await wrapper.GetJobRunsAsync(jobName);

    jobRuns.ForEach(jobRun =>
    {
        Console.WriteLine($"{jobRun.JobName}\t{jobRun.JobRunState}\t{jobRun.CompletedOn}");
    });

    uiWrapper.PressEnter();

    uiWrapper.DisplayTitle("Deleting resources");
    Console.WriteLine("Deleting the AWS Glue job used by the example.");
    await wrapper.DeleteJobAsync(jobName);

    Console.WriteLine("Deleting the tables from the database.");
    tables.ForEach(async table =>
```

```

        {
            await wrapper.DeleteTableAsync(dbName, table.Name);
        });

        Console.WriteLine("Deleting the database.");
        await wrapper.DeleteDatabaseAsync(dbName);

        Console.WriteLine("Deleting the AWS Glue crawler.");
        await wrapper.DeleteCrawlerAsync(crawlerName);

        Console.WriteLine("The AWS Glue scenario has completed.");
        uiWrapper.PressEnter();
    }
}

namespace GlueBasics;

public class UiWrapper
{
    public readonly string SepBar = new string('-', Console.WindowWidth);

    /// <summary>
    /// Show information about the scenario.
    /// </summary>
    public void DisplayOverview()
    {
        Console.Clear();
        DisplayTitle("Amazon Glue: get started with crawlers and jobs");

        Console.WriteLine("This example application does the following:");
        Console.WriteLine("\t 1. Create a crawler, pass it the IAM role and the
URL to the public S3 bucket that contains the source data");
        Console.WriteLine("\t 2. Start the crawler.");
        Console.WriteLine("\t 3. Get the database created by the crawler and the
tables in the database.");
        Console.WriteLine("\t 4. Create a job.");
        Console.WriteLine("\t 5. Start a job run.");
        Console.WriteLine("\t 6. Wait for the job run to complete.");
        Console.WriteLine("\t 7. Show the data stored in the bucket.");
        Console.WriteLine("\t 8. List jobs for the account.");
        Console.WriteLine("\t 9. Get job run details for the job that was run.");
        Console.WriteLine("\t10. Delete the demo job.");
    }
}

```

```

        Console.WriteLine("\t11. Delete the database and tables created for the
demo.");
        Console.WriteLine("\t12. Delete the crawler.");
    }

    /// <summary>
    /// Display a message and wait until the user presses enter.
    /// </summary>
    public void PressEnter()
    {
        Console.Write("\nPlease press <Enter> to continue. ");
        _ = Console.ReadLine();
    }

    /// <summary>
    /// Pad a string with spaces to center it on the console display.
    /// </summary>
    /// <param name="strToCenter">The string to center on the screen.</param>
    /// <returns>The string padded to make it center on the screen.</returns>
    public string CenterString(string strToCenter)
    {
        var padAmount = (Console.WindowWidth - strToCenter.Length) / 2;
        var leftPad = new string(' ', padAmount);
        return $"{leftPad}{strToCenter}";
    }

    /// <summary>
    /// Display a line of hyphens, the centered text of the title and another
    /// line of hyphens.
    /// </summary>
    /// <param name="strTitle">The string to be displayed.</param>
    public void DisplayTitle(string strTitle)
    {
        Console.WriteLine(SepBar);
        Console.WriteLine(CenterString(strTitle));
        Console.WriteLine(SepBar);
    }
}

```

- Pour plus d'informations sur l'API consultez les rubriques suivantes dans la référence de l'API AWS SDK pour .NET .

- [CreateCrawler](#)
- [CreateJob](#)
- [DeleteCrawler](#)
- [DeleteDatabase](#)
- [DeleteJob](#)
- [DeleteTable](#)
- [GetCrawler](#)
- [GetDatabase](#)
- [GetDatabases](#)
- [GetJob](#)
- [GetJobRun](#)
- [GetJobRuns](#)
- [GetTables](#)
- [ListJobs](#)
- [StartCrawler](#)
- [StartJobRun](#)

C++

SDK pour C++

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
#!/ Scenario which demonstrates using AWS Glue to add a crawler and run a job.
/*!
\\sa runGettingStartedWithGlueScenario()
\param bucketName: An S3 bucket created in the setup.
\param roleName: An AWS Identity and Access Management (IAM) role created in the
setup.
\param clientConfig: AWS client configuration.
\return bool: Successful completion.
```

```

*/

bool AwsDoc::Glue::runGettingStartedWithGlueScenario(const Aws::String
&bucketName,

                                                    const Aws::String &roleName,
                                                    const
Aws::Client::ClientConfiguration &clientConfig) {
    Aws::Glue::GlueClient client(clientConfig);

    Aws::String roleArn;
    if (!getRoleArn(roleName, roleArn, clientConfig)) {
        std::cerr << "Error getting role ARN for role." << std::endl;
        return false;
    }

    // 1. Upload the job script to the S3 bucket.
    {
        std::cout << "Uploading the job script '"
                    << AwsDoc::Glue::PYTHON_SCRIPT
                    << "'." << std::endl;

        if (!AwsDoc::Glue::uploadFile(bucketName,
                                        AwsDoc::Glue::PYTHON_SCRIPT_PATH,
                                        AwsDoc::Glue::PYTHON_SCRIPT,
                                        clientConfig)) {
            std::cerr << "Error uploading the job file." << std::endl;
            return false;
        }
    }

    // 2. Create a crawler.
    {
        Aws::Glue::Model::S3Target s3Target;
        s3Target.SetPath("s3://crawler-public-us-east-1/flight/2016/csv");
        Aws::Glue::Model::CrawlerTargets crawlerTargets;
        crawlerTargets.AddS3Targets(s3Target);

        Aws::Glue::Model::CreateCrawlerRequest request;
        request.SetTargets(crawlerTargets);
        request.SetName(CRAWLER_NAME);
        request.SetDatabaseName(CRAWLER_DATABASE_NAME);
        request.SetTablePrefix(CRAWLER_DATABASE_PREFIX);
        request.SetRole(roleArn);
    }
}

```

```

        Aws::Glue::Model::CreateCrawlerOutcome outcome =
client.CreateCrawler(request);

        if (outcome.IsSuccess()) {
            std::cout << "Successfully created the crawler." << std::endl;
        }
        else {
            std::cerr << "Error creating a crawler. " <<
outcome.GetError().GetMessage()
                << std::endl;
            deleteAssets("", CRAWLER_DATABASE_NAME, "", bucketName,
clientConfig);
            return false;
        }
    }

// 3. Get a crawler.
{
    Aws::Glue::Model::GetCrawlerRequest request;
    request.SetName(CRAWLER_NAME);

    Aws::Glue::Model::GetCrawlerOutcome outcome = client.GetCrawler(request);

    if (outcome.IsSuccess()) {
        Aws::Glue::Model::CrawlerState crawlerState =
outcome.GetResult().GetCrawler().GetState();
        std::cout << "Retrieved crawler with state " <<

Aws::Glue::Model::CrawlerStateMapper::GetNameForCrawlerState(
            crawlerState)
            << "." << std::endl;
    }
    else {
        std::cerr << "Error retrieving a crawler. "
            << outcome.GetError().GetMessage() << std::endl;
        deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
            clientConfig);
        return false;
    }
}

// 4. Start a crawler.
{
    Aws::Glue::Model::StartCrawlerRequest request;

```

```

    request.SetName(CRAWLER_NAME);

    Aws::Glue::Model::StartCrawlerOutcome outcome =
client.StartCrawler(request);

    if (outcome.IsSuccess() || (Aws::Glue::GlueErrors::CRAWLER_RUNNING ==
                                outcome.GetError().GetErrorType())) {
        if (!outcome.IsSuccess()) {
            std::cout << "Crawler was already started." << std::endl;
        }
        else {
            std::cout << "Successfully started crawler." << std::endl;
        }

        std::cout << "This may take a while to run." << std::endl;

        Aws::Glue::Model::CrawlerState crawlerState =
Aws::Glue::Model::CrawlerState::NOT_SET;
        int iterations = 0;
        while (Aws::Glue::Model::CrawlerState::READY != crawlerState) {
            std::this_thread::sleep_for(std::chrono::seconds(1));
            ++iterations;
            if ((iterations % 10) == 0) { // Log status every 10 seconds.
                std::cout << "Crawler status " <<

Aws::Glue::Model::CrawlerStateMapper::GetNameForCrawlerState(
                                crawlerState)
                << ". After " << iterations
                << " seconds elapsed."
                << std::endl;
            }
            Aws::Glue::Model::GetCrawlerRequest getCrawlerRequest;
            getCrawlerRequest.SetName(CRAWLER_NAME);

            Aws::Glue::Model::GetCrawlerOutcome getCrawlerOutcome =
client.GetCrawler(
                                getCrawlerRequest);

            if (getCrawlerOutcome.IsSuccess()) {
                crawlerState =
getCrawlerOutcome.GetResult().GetCrawler().GetState();
            }
            else {

```



```

        std::cerr << "Error getting crawler.  "
        << getCrawlerOutcome.GetError().GetMessage() <<
std::endl;
        break;
    }
}

if (Aws::Glue::Model::CrawlerState::READY == crawlerState) {
    std::cout << "Crawler finished running after " << iterations
    << " seconds."
    << std::endl;
}
}
else {
    std::cerr << "Error starting a crawler.  "
    << outcome.GetError().GetMessage()
    << std::endl;

    deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
        clientConfig);
    return false;
}
}

// 5. Get a database.
{
    Aws::Glue::Model::GetDatabaseRequest request;
    request.SetName(CRAWLER_DATABASE_NAME);

    Aws::Glue::Model::GetDatabaseOutcome outcome =
client.GetDatabase(request);

    if (outcome.IsSuccess()) {
        const Aws::Glue::Model::Database &database =
outcome.GetResult().GetDatabase();

        std::cout << "Successfully retrieve the database\n" <<
        database.Jsonize().View().WriteReadable() << "'. " <<
std::endl;
    }
    else {
        std::cerr << "Error getting the database.  "
        << outcome.GetError().GetMessage() << std::endl;
        deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,

```

```

        clientConfig);
    return false;
}
}

// 6. Get tables.
Aws::String tableName;
{
    Aws::Glue::Model::GetTablesRequest request;
    request.SetDatabaseName(CRAWLER_DATABASE_NAME);
    std::vector<Aws::Glue::Model::Table> all_tables;
    Aws::String nextToken; // Used for pagination.
    do {
        Aws::Glue::Model::GetTablesOutcome outcome =
client.GetTables(request);

        if (outcome.IsSuccess()) {
            const std::vector<Aws::Glue::Model::Table> &tables =
outcome.GetResult().GetTableList();
            all_tables.insert(all_tables.end(), tables.begin(),
tables.end());
            nextToken = outcome.GetResult().GetNextToken();
        }
        else {
            std::cerr << "Error getting the tables. "
                << outcome.GetError().GetMessage()
                << std::endl;
            deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
clientConfig);
            return false;
        }
    } while (!nextToken.empty());

    std::cout << "The database contains " << all_tables.size()
        << (all_tables.size() == 1 ?
            " table." : " tables.") << std::endl;
    std::cout << "Here is a list of the tables in the database.";
    for (size_t index = 0; index < all_tables.size(); ++index) {
        std::cout << "    " << index + 1 << ": " <<
all_tables[index].GetName()
            << std::endl;
    }

    if (!all_tables.empty()) {

```

```

        int tableIndex = askQuestionForIntRange(
            "Enter an index to display the database detail ",
            1, static_cast<int>(all_tables.size()));
        std::cout << all_tables[tableIndex -
1].Jsonize().View().WriteReadable()
            << std::endl;

        tableName = all_tables[tableIndex - 1].GetName();
    }
}

// 7. Create a job.
{
    Aws::Glue::Model::CreateJobRequest request;
    request.SetName(JOB_NAME);
    request.SetRole(roleArn);
    request.SetGlueVersion(GLUE_VERSION);

    Aws::Glue::Model::JobCommand command;
    command.SetName(JOB_COMMAND_NAME);
    command.SetPythonVersion(JOB_PYTHON_VERSION);
    command.SetScriptLocation(
        Aws::String("s3://") + bucketName + "/" + PYTHON_SCRIPT);
    request.SetCommand(command);

    Aws::Glue::Model::CreateJobOutcome outcome = client.CreateJob(request);

    if (outcome.IsSuccess()) {
        std::cout << "Successfully created the job." << std::endl;
    }
    else {
        std::cerr << "Error creating the job. " <<
outcome.GetError().GetMessage()
            << std::endl;
        deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
            clientConfig);
        return false;
    }
}

// 8. Start a job run.
{
    Aws::Glue::Model::StartJobRunRequest request;
    request.SetJobName(JOB_NAME);

```

```

    Aws::Map<Aws::String, Aws::String> arguments;
    arguments["--input_database"] = CRAWLER_DATABASE_NAME;
    arguments["--input_table"] = tableName;
    arguments["--output_bucket_url"] = Aws::String("s3://") + bucketName +
"/";
    request.SetArguments(arguments);

    Aws::Glue::Model::StartJobRunOutcome outcome =
client.StartJobRun(request);

    if (outcome.IsSuccess()) {
        std::cout << "Successfully started the job." << std::endl;

        Aws::String jobRunId = outcome.GetResult().GetJobRunId();

        int iterator = 0;
        bool done = false;
        while (!done) {
            ++iterator;
            std::this_thread::sleep_for(std::chrono::seconds(1));
            Aws::Glue::Model::GetJobRunRequest jobRunRequest;
            jobRunRequest.SetJobName(JOB_NAME);
            jobRunRequest.SetRunId(jobRunId);

            Aws::Glue::Model::GetJobRunOutcome jobRunOutcome =
client.GetJobRun(
                jobRunRequest);

            if (jobRunOutcome.IsSuccess()) {
                const Aws::Glue::Model::JobRun &jobRun =
jobRunOutcome.GetResult().GetJobRun();
                Aws::Glue::Model::JobRunState jobRunState =
jobRun.GetJobRunState();

                if ((jobRunState == Aws::Glue::Model::JobRunState::STOPPED)
||
                    (jobRunState == Aws::Glue::Model::JobRunState::FAILED) ||
                    (jobRunState == Aws::Glue::Model::JobRunState::TIMEOUT))
{
                    std::cerr << "Error running job. "
                        << jobRun.GetErrorMessage()
                        << std::endl;

```

```

        deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME,
JOB_NAME,
                    bucketName,
                    clientConfig);
        return false;
    }
    else if (jobRunState ==
        Aws::Glue::Model::JobRunState::SUCCEEDED) {
        std::cout << "Job run succeeded after " << iterator <<
            " seconds elapsed." << std::endl;
        done = true;
    }
    else if ((iterator % 10) == 0) { // Log status every 10
seconds.
        std::cout << "Job run status " <<

Aws::Glue::Model::JobRunStateMapper::GetNameForJobRunState(
                    jobRunState) <<
            ". " << iterator <<
            " seconds elapsed." << std::endl;
    }
}
else {
    std::cerr << "Error retrieving job run state. "
        << jobRunOutcome.GetError().GetMessage()
        << std::endl;
    deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, JOB_NAME,
        bucketName, clientConfig);
    return false;
}
}
}
else {
    std::cerr << "Error starting a job. " <<
outcome.GetError().GetMessage()
        << std::endl;
    deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, JOB_NAME,
bucketName,
                    clientConfig);
    return false;
}
}

// 9. List the output data stored in the S3 bucket.

```

```

{
    Aws::S3::S3Client s3Client;
    Aws::S3::Model::ListObjectsV2Request request;
    request.SetBucket(bucketName);
    request.SetPrefix(OUTPUT_FILE_PREFIX);

    Aws::String continuationToken; // Used for pagination.
    std::vector<Aws::S3::Model::Object> allObjects;
    do {
        if (!continuationToken.empty()) {
            request.SetContinuationToken(continuationToken);
        }
        Aws::S3::Model::ListObjectsV2Outcome outcome =
s3Client.ListObjectsV2(
            request);

        if (outcome.IsSuccess()) {
            const std::vector<Aws::S3::Model::Object> &objects =
                outcome.GetResult().GetContents();
            allObjects.insert(allObjects.end(), objects.begin(),
objects.end());
            continuationToken =
outcome.GetResult().GetNextContinuationToken();
        }
        else {
            std::cerr << "Error listing objects. "
                << outcome.GetError().GetMessage()
                << std::endl;

            break;
        }
    } while (!continuationToken.empty());

    std::cout << "Data from your job is in " << allObjects.size() <<
        " files in the S3 bucket, " << bucketName << "." << std::endl;

    for (size_t i = 0; i < allObjects.size(); ++i) {
        std::cout << "    " << i + 1 << ". " << allObjects[i].GetKey()
            << std::endl;
    }

    int objectIndex = askQuestionForIntRange(
        std::string(
            "Enter the number of a block to download it and see the
first ") +

```

```

        std::to_string(LINES_OF_RUN_FILE_TO_DISPLAY) +
        " lines of JSON output in the block: ", 1,
        static_cast<int>(allObjects.size()));

    Aws::String objectKey = allObjects[objectIndex - 1].GetKey();

    std::stringstream stringStream;
    if (getObjectFromBucket(bucketName, objectKey, stringStream,
                           clientConfig)) {
        for (int i = 0; i < LINES_OF_RUN_FILE_TO_DISPLAY && stringStream; +
+i) {
            std::string line;
            std::getline(stringStream, line);
            std::cout << "    " << line << std::endl;
        }
    }
    else {
        deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, JOB_NAME,
bucketName,
                    clientConfig);
        return false;
    }
}

// 10. List all the jobs.
Aws::String jobName;
{
    Aws::Glue::Model::ListJobsRequest listJobsRequest;

    Aws::String nextToken;
    std::vector<Aws::String> allJobNames;

    do {
        if (!nextToken.empty()) {
            listJobsRequest.SetNextToken(nextToken);
        }
        Aws::Glue::Model::ListJobsOutcome listRunsOutcome = client.ListJobs(
            listJobsRequest);

        if (listRunsOutcome.IsSuccess()) {
            const std::vector<Aws::String> &jobNames =
listRunsOutcome.GetResult().GetJobNames();
            allJobNames.insert(allJobNames.end(), jobNames.begin(),
jobNames.end());

```

```

        nextToken = listRunsOutcome.GetResult().GetNextToken();
    }
    else {
        std::cerr << "Error listing jobs. "
                  << listRunsOutcome.GetError().GetMessage()
                  << std::endl;
    }
} while (!nextToken.empty());
std::cout << "Your account has " << allJobNames.size() << " jobs."
          << std::endl;
for (size_t i = 0; i < allJobNames.size(); ++i) {
    std::cout << "    " << i + 1 << ". " << allJobNames[i] << std::endl;
}
int jobIndex = askQuestionForIntRange(
    Aws::String("Enter a number between 1 and ") +
    std::to_string(allJobNames.size()) +
    " to see the list of runs for a job: ",
    1, static_cast<int>(allJobNames.size()));

jobName = allJobNames[jobIndex - 1];
}

// 11. Get the job runs for a job.
Aws::String jobRunID;
if (!jobName.empty()) {
    Aws::Glue::Model::GetJobRunsRequest getJobRunsRequest;
    getJobRunsRequest.SetJobName(jobName);

    Aws::String nextToken; // Used for pagination.
    std::vector<Aws::Glue::Model::JobRun> allJobRuns;
    do {
        if (!nextToken.empty()) {
            getJobRunsRequest.SetNextToken(nextToken);
        }
        Aws::Glue::Model::GetJobRunsOutcome jobRunsOutcome =
client.GetJobRuns(
    getJobRunsRequest);

        if (jobRunsOutcome.IsSuccess()) {
            const std::vector<Aws::Glue::Model::JobRun> &jobRuns =
jobRunsOutcome.GetResult().GetJobRuns();
            allJobRuns.insert(allJobRuns.end(), jobRuns.begin(),
jobRuns.end());

```



```

        nextToken = jobRunsOutcome.GetResult().GetNextToken();
    }
    else {
        std::cerr << "Error getting job runs. "
                  << jobRunsOutcome.GetError().GetMessage()
                  << std::endl;

        break;
    }
} while (!nextToken.empty());

std::cout << "There are " << allJobRuns.size() << " runs in the job '"
          <<
          jobName << "'." << std::endl;

for (size_t i = 0; i < allJobRuns.size(); ++i) {
    std::cout << "    " << i + 1 << ". " << allJobRuns[i].GetJobName()
              << std::endl;
}

int runIndex = askQuestionForIntRange(
    Aws::String("Enter a number between 1 and ") +
    std::to_string(allJobRuns.size()) +
    " to see details for a run: ",
    1, static_cast<int>(allJobRuns.size()));
jobRunID = allJobRuns[runIndex - 1].GetId();
}

// 12. Get a single job run.
if (!jobRunID.empty()) {
    Aws::Glue::Model::GetJobRunRequest jobRunRequest;
    jobRunRequest.SetJobName(jobName);
    jobRunRequest.SetRunId(jobRunID);

    Aws::Glue::Model::GetJobRunOutcome jobRunOutcome = client.GetJobRun(
        jobRunRequest);

    if (jobRunOutcome.IsSuccess()) {
        std::cout << "Displaying the job run JSON description." << std::endl;
        std::cout
            <<
jobRunOutcome.GetResult().GetJobRun().Jsonize().View().WriteReadable()
            << std::endl;
    }
    else {

```

```

        std::cerr << "Error get a job run. "
        << jobRunOutcome.GetError().GetMessage()
        << std::endl;
    }
}

return deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, JOB_NAME,
bucketName,

                    clientConfig);
}

//! Cleanup routine to delete created assets.
/*!
\\sa deleteAssets()
\\param crawler: Name of an AWS Glue crawler.
\\param database: The name of an AWS Glue database.
\\param job: The name of an AWS Glue job.
\\param bucketName: The name of an S3 bucket.
\\param clientConfig: AWS client configuration.
\\return bool: Successful completion.
*/
bool AwsDoc::Glue::deleteAssets(const Aws::String &crawler, const Aws::String
&database,

                                const Aws::String &job, const Aws::String
&bucketName,

                                const Aws::Client::ClientConfiguration
&clientConfig) {
    const Aws::Glue::GlueClient client(clientConfig);
    bool result = true;

    // 13. Delete a job.
    if (!job.empty()) {
        Aws::Glue::Model::DeleteJobRequest request;
        request.SetJobName(job);

        Aws::Glue::Model::DeleteJobOutcome outcome = client.DeleteJob(request);

        if (outcome.IsSuccess()) {
            std::cout << "Successfully deleted the job." << std::endl;
        }
        else {
            std::cerr << "Error deleting the job. " <<
outcome.GetError().GetMessage()

```

```

        << std::endl;
        result = false;
    }
}

// 14. Delete a database.
if (!database.empty()) {
    Aws::Glue::Model::DeleteDatabaseRequest request;
    request.SetName(database);

    Aws::Glue::Model::DeleteDatabaseOutcome outcome = client.DeleteDatabase(
        request);

    if (outcome.IsSuccess()) {
        std::cout << "Successfully deleted the database." << std::endl;
    }
    else {
        std::cerr << "Error deleting database. " <<
outcome.GetError().GetMessage()
        << std::endl;
        result = false;
    }
}

// 15. Delete a crawler.
if (!crawler.empty()) {
    Aws::Glue::Model::DeleteCrawlerRequest request;
    request.SetName(crawler);

    Aws::Glue::Model::DeleteCrawlerOutcome outcome =
client.DeleteCrawler(request);

    if (outcome.IsSuccess()) {
        std::cout << "Successfully deleted the crawler." << std::endl;
    }
    else {
        std::cerr << "Error deleting the crawler. "
        << outcome.GetError().GetMessage() << std::endl;
        result = false;
    }
}

// 16. Delete the job script and run data from the S3 bucket.
result &= AwsDoc::Glue::deleteAllObjectsInS3Bucket(bucketName,

```

```

        clientConfig);

    return result;
}

//! Routine which uploads a file to an S3 bucket.
/*!
    \\sa uploadFile()
    \\param bucketName: An S3 bucket created in the setup.
    \\param filePath: The path of the file to upload.
    \\param fileName The name for the uploaded file.
    \\param clientConfig: AWS client configuration.
    \\return bool: Successful completion.
*/
bool
AwsDoc::Glue::uploadFile(const Aws::String &bucketName,
                        const Aws::String &filePath,
                        const Aws::String &fileName,
                        const Aws::Client::ClientConfiguration &clientConfig) {
    Aws::S3::S3Client s3_client(clientConfig);

    Aws::S3::Model::PutObjectRequest request;
    request.SetBucket(bucketName);
    request.SetKey(fileName);

    std::shared_ptr<Aws::IOStream> inputData =
        Aws::MakeShared<Aws::FStream>("SampleAllocationTag",
                                      filePath.c_str(),
                                      std::ios_base::in |
std::ios_base::binary);

    if (!*inputData) {
        std::cerr << "Error unable to read file " << filePath << std::endl;
        return false;
    }

    request.SetBody(inputData);

    Aws::S3::Model::PutObjectOutcome outcome =
        s3_client.PutObject(request);

    if (!outcome.IsSuccess()) {
        std::cerr << "Error: PutObject: " <<
            outcome.GetError().GetMessage() << std::endl;
    }
}

```

```

    else {
        std::cout << "Added object '" << filePath << "' to bucket '"
            << bucketName << "'." << std::endl;
    }

    return outcome.IsSuccess();
}

//! Routine which deletes all objects in an S3 bucket.
/*!
    \sa deleteAllObjectsInS3Bucket()
    \param bucketName: The S3 bucket name.
    \param clientConfig: AWS client configuration.
    \return bool: Successful completion.
    */
bool AwsDoc::Glue::deleteAllObjectsInS3Bucket(const Aws::String &bucketName,
                                              const
    Aws::Client::ClientConfiguration &clientConfig) {
    Aws::S3::S3Client client(clientConfig);
    Aws::S3::Model::ListObjectsV2Request listObjectsRequest;
    listObjectsRequest.SetBucket(bucketName);

    Aws::String continuationToken; // Used for pagination.
    bool result = true;
    do {
        if (!continuationToken.empty()) {
            listObjectsRequest.SetContinuationToken(continuationToken);
        }

        Aws::S3::Model::ListObjectsV2Outcome listObjectsOutcome =
        client.ListObjectsV2(
            listObjectsRequest);

        if (listObjectsOutcome.IsSuccess()) {
            const std::vector<Aws::S3::Model::Object> &objects =
        listObjectsOutcome.GetResult().GetContents();
            if (!objects.empty()) {
                Aws::S3::Model::DeleteObjectsRequest deleteObjectsRequest;
                deleteObjectsRequest.SetBucket(bucketName);

                std::vector<Aws::S3::Model::ObjectIdentifier> objectIdentifiers;
                for (const Aws::S3::Model::Object &object: objects) {
                    objectIdentifiers.push_back(
                        Aws::S3::Model::ObjectIdentifier().WithKey(

```

```

        object.GetKey()));
    }
    Aws::S3::Model::DeleteObjectsDeleteRequest objectsDelete;
    objectsDelete.SetObjects(objectIdentifiers);
    objectsDelete.SetQuiet(true);
    deleteObjectsRequest.SetDelete(objectsDelete);

    Aws::S3::Model::DeleteObjectsOutcome deleteObjectsOutcome =
        client.DeleteObjects(deleteObjectsRequest);

    if (!deleteObjectsOutcome.IsSuccess()) {
        std::cerr << "Error deleting objects. " <<
            deleteObjectsOutcome.GetError().GetMessage() <<
std::endl;
        result = false;
        break;
    }
    else {
        std::cout << "Successfully deleted the objects." <<
std::endl;
    }

    }
    else {
        std::cout << "No objects to delete in '" << bucketName << "'."
            << std::endl;
    }

    continuationToken =
listObjectsOutcome.GetResult().GetNextContinuationToken();
    }
    else {
        std::cerr << "Error listing objects. "
            << listObjectsOutcome.GetError().GetMessage() << std::endl;
        result = false;
        break;
    }
} while (!continuationToken.empty());

return result;
}

//! Routine which retrieves an object from an S3 bucket.
/*!

```

```

\\sa getObjectFromBucket()
\param bucketName: The S3 bucket name.
\param objectKey: The object's name.
\param objectStream: A stream to receive the retrieved data.
\param clientConfig: AWS client configuration.
\return bool: Successful completion.
*/
bool AwsDoc::Glue::getObjectFromBucket(const Aws::String &bucketName,
                                       const Aws::String &objectKey,
                                       std::ostream &objectStream,
                                       const Aws::Client::ClientConfiguration
&clientConfig) {
    Aws::S3::S3Client client(clientConfig);
    Aws::S3::Model::GetObjectRequest request;
    request.SetBucket(bucketName);
    request.SetKey(objectKey);

    Aws::S3::Model::GetObjectOutcome outcome = client.GetObject(request);

    if (outcome.IsSuccess()) {
        std::cout << "Successfully retrieved '" << objectKey << "'." <<
std::endl;
        auto &body = outcome.GetResult().GetBody();
        objectStream << body.rdbuf();
    }
    else {
        std::cerr << "Error retrieving object. " <<
outcome.GetError().GetMessage()
        << std::endl;
    }

    return outcome.IsSuccess();
}

```

- Pour plus d'informations sur l'API, consultez les rubriques suivantes dans la référence de l'API AWS SDK pour C++ .
 - [CreateCrawler](#)
 - [CreateJob](#)
 - [DeleteCrawler](#)

- [DeleteDatabase](#)
- [DeleteJob](#)
- [DeleteTable](#)
- [GetCrawler](#)
- [GetDatabase](#)
- [GetDatabases](#)
- [GetJob](#)
- [GetJobRun](#)
- [GetJobRuns](#)
- [GetTables](#)
- [ListJobs](#)
- [StartCrawler](#)
- [StartJobRun](#)

Java

SDK pour Java 2.x

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/**
 * Before running this Java V2 code example, set up your development
 * environment, including your credentials.
 * <p>
 * For more information, see the following documentation topic:
 *
 * https://docs.aws.amazon.com/sdk-for-java/latest/developer-guide/get-started.html
 *
 * To set up the resources, see this documentation topic:
 *
```



```

* https://docs.aws.amazon.com/glue/latest/ug/tutorial-add-crawler.html
*
* This example performs the following tasks:
*
* 1. Create a database.
* 2. Create a crawler.
* 3. Get a crawler.
* 4. Start a crawler.
* 5. Get a database.
* 6. Get tables.
* 7. Create a job.
* 8. Start a job run.
* 9. List all jobs.
* 10. Get job runs.
* 11. Delete a job.
* 12. Delete a database.
* 13. Delete a crawler.
*/

```

```

public class GlueScenario {
    public static final String DASHES = new String(new char[80]).replace("\0",
"-");

    public static void main(String[] args) throws InterruptedException {
        final String usage = ""

        Usage:
            <iam> <s3Path> <cron> <dbName> <crawlerName> <jobName>
<scriptLocation> <locationUri> <bucketNameSc>\s

        Where:
            iam - The ARN of the IAM role that has AWS Glue and S3
permissions.\s
            s3Path - The Amazon Simple Storage Service (Amazon S3) target
that contains data (for example, s3://<bucket name>/read).
            cron - A cron expression used to specify the schedule (i.e.,
cron(15 12 * * ? *).
            dbName - The database name.\s
            crawlerName - The name of the crawler.\s
            jobName - The name you assign to this job definition.
            scriptLocation - The Amazon S3 path to a script that runs a job.
            locationUri - The location of the database (you can find this
file in resources folder).
            bucketNameSc - The Amazon S3 bucket name used when creating a job

```

```
        """;

    if (args.length != 9) {
        System.out.println(usage);
        return;
    }
    Scanner scanner = new Scanner(System.in);
    String iam = args[0];
    String s3Path = args[1];
    String cron = args[2];
    String dbName = args[3];
    String crawlerName = args[4];
    String jobName = args[5];
    String scriptLocation = args[6];
    String locationUri = args[7];
    String bucketNameSc = args[8];

    Region region = Region.US_EAST_1;
    GlueClient glueClient = GlueClient.builder()
        .region(region)
        .build();
    System.out.println(DASHES);
    System.out.println("Welcome to the AWS Glue scenario.");
    System.out.println("""
        AWS Glue is a fully managed extract, transform, and load (ETL)
service provided by Amazon
        Web Services (AWS). It is designed to simplify the process of
building, running, and maintaining
        ETL pipelines, which are essential for data integration and data
warehousing tasks.

        One of the key features of AWS Glue is its ability to automatically
discover and catalog data
        stored in various sources, such as Amazon S3, Amazon RDS, Amazon
Redshift, and other databases.
        This cataloging process creates a central metadata repository, known
as the AWS Glue Data Catalog,
        which provides a unified view of an organization's data assets. This
metadata can then be used to
        create ETL jobs, which can be scheduled and run on-demand or on a
regular basis.

        Lets get started.
```

```
        """);
    waitForInputToContinue(scanner);
    System.out.println(DASHES);

    System.out.println(DASHES);
    System.out.println("1. Create a database.");
    try {
        createDatabase(glueClient, dbName, locationUri);
    } catch (GlueException e) {
        if (e.awsErrorDetails().errorMessage().equals("Database already
exists.)) {
            System.out.println("Database " + dbName + " already exists.
Skipping creation.");
        } else {
            System.err.println(e.awsErrorDetails().errorMessage());
            return;
        }
    }

    waitForInputToContinue(scanner);
    System.out.println(DASHES);

    System.out.println(DASHES);
    System.out.println("2. Create a crawler.");
    try {
        createGlueCrawler(glueClient, iam, s3Path, cron, dbName,
crawlerName);
    } catch (GlueException e) {
        if (e.awsErrorDetails().errorMessage().contains("already exists")) {
            System.out.println("Crawler " + crawlerName + " already exists.
Skipping creation.");
        } else {
            System.err.println(e.awsErrorDetails().errorMessage());
            System.exit(1);
        }
    }

    waitForInputToContinue(scanner);
    System.out.println(DASHES);

    System.out.println(DASHES);
    System.out.println("3. Get a crawler.");
    try {
        getSpecificCrawler(glueClient, crawlerName);
    } catch (GlueException e) {
```

```
        System.err.println(e.awsErrorDetails().errorMessage());
        return;
    }
    waitForInputToContinue(scanner);
    System.out.println(DASHES);

    System.out.println(DASHES);
    System.out.println("4. Start a crawler.");
    try {
        startSpecificCrawler(glueClient, crawlerName);
    } catch (GlueException e) {
        System.err.println(e.awsErrorDetails().errorMessage());
        return;
    }
    waitForInputToContinue(scanner);
    System.out.println(DASHES);

    System.out.println(DASHES);
    System.out.println("5. Get a database.");
    try {
        getSpecificDatabase(glueClient, dbName);
    } catch (GlueException e) {
        System.err.println(e.awsErrorDetails().errorMessage());
        return;
    }
    waitForInputToContinue(scanner);
    System.out.println(DASHES);

    System.out.println(DASHES);
    System.out.println("**** Wait 5 min for the tables to become available");
    TimeUnit.MINUTES.sleep(5);
    System.out.println("6. Get tables.");
    String myTableName;
    try {
        myTableName = getGlueTables(glueClient, dbName);
    } catch (GlueException e) {
        System.err.println(e.awsErrorDetails().errorMessage());
        return;
    }
    waitForInputToContinue(scanner);
    System.out.println(DASHES);

    System.out.println(DASHES);
    System.out.println("7. Create a job.");
```

```
try {
    createJob(glueClient, jobName, iam, scriptLocation);
} catch (GlueException e) {
    System.err.println(e.awsErrorDetails().errorMessage());
    return;
}
waitForInputToContinue(scanner);
System.out.println(DASHES);

System.out.println(DASHES);
System.out.println("8. Start a Job run.");
try {
    startJob(glueClient, jobName, dbName, myTableName, bucketNameSc);
} catch (GlueException e) {
    System.err.println(e.awsErrorDetails().errorMessage());
    return;
}
waitForInputToContinue(scanner);
System.out.println(DASHES);

System.out.println(DASHES);
System.out.println("9. List all jobs.");
try {
    getAllJobs(glueClient);
} catch (GlueException e) {
    System.err.println(e.awsErrorDetails().errorMessage());
    return;
}
waitForInputToContinue(scanner);
System.out.println(DASHES);

System.out.println(DASHES);
System.out.println("10. Get job runs.");
try {
    getJobRuns(glueClient, jobName);
} catch (GlueException e) {
    System.err.println(e.awsErrorDetails().errorMessage());
    return;
}
waitForInputToContinue(scanner);
System.out.println(DASHES);

System.out.println(DASHES);
System.out.println("11. Delete a job.");
```

```

    try {
        deleteJob(glueClient, jobName);
    } catch (GlueException e) {
        System.err.println(e.awsErrorDetails().errorMessage());
        return;
    }
    System.out.println("*** Wait 5 MIN for the " + crawlerName + " to stop");
    TimeUnit.MINUTES.sleep(5);
    waitForInputToContinue(scanner);
    System.out.println(DASHES);

    System.out.println(DASHES);
    System.out.println("12. Delete a database.");
    try {
        deleteDatabase(glueClient, dbName);
    } catch (GlueException e) {
        System.err.println(e.awsErrorDetails().errorMessage());
        return;
    }
    waitForInputToContinue(scanner);
    System.out.println(DASHES);

    System.out.println(DASHES);
    System.out.println("Delete a crawler.");
    try {
        deleteSpecificCrawler(glueClient, crawlerName);
    } catch (GlueException e) {
        System.err.println(e.awsErrorDetails().errorMessage());
        return;
    }
    waitForInputToContinue(scanner);
    System.out.println(DASHES);

    System.out.println(DASHES);
    System.out.println("Successfully completed the AWS Glue Scenario");
    System.out.println(DASHES);
}

/**
 * Creates a Glue database with the specified name and location URI.
 *
 * @param glueClient The Glue client to use for the database creation.
 * @param dbName     The name of the database to create.

```

```

    * @param locationUri The location URI for the database.
    */
    public static void createDatabase(GlueClient glueClient, String dbName,
String locationUri) {
        try {
            DatabaseInput input = DatabaseInput.builder()
                .description("Built with the AWS SDK for Java V2")
                .name(dbName)
                .locationUri(locationUri)
                .build();

            CreateDatabaseRequest request = CreateDatabaseRequest.builder()
                .databaseInput(input)
                .build();

            glueClient.createDatabase(request);
            System.out.println(dbName + " was successfully created");

        } catch (GlueException e) {
            throw e;
        }
    }

    /**
     * Creates a new AWS Glue crawler using the AWS Glue Java API.
     *
     * @param glueClient the AWS Glue client used to interact with the AWS Glue
service
     * @param iam the IAM role that the crawler will use to access the
data source
     * @param s3Path the S3 path that the crawler will scan for data
     * @param cron the cron expression that defines the crawler's schedule
     * @param dbName the name of the AWS Glue database where the crawler
will store the metadata
     * @param crawlerName the name of the crawler to be created
     */
    public static void createGlueCrawler(GlueClient glueClient,
String iam,
String s3Path,
String cron,
String dbName,
String crawlerName) {

```

```

    try {
        S3Target s3Target = S3Target.builder()
            .path(s3Path)
            .build();

        List<S3Target> targetList = new ArrayList<>();
        targetList.add(s3Target);
        CrawlerTargets targets = CrawlerTargets.builder()
            .s3Targets(targetList)
            .build();

        CreateCrawlerRequest crawlerRequest = CreateCrawlerRequest.builder()
            .databaseName(dbName)
            .name(crawlerName)
            .description("Created by the AWS Glue Java API")
            .targets(targets)
            .role(iam)
            .schedule(cron)
            .build();

        glueClient.createCrawler(crawlerRequest);
        System.out.println(crawlerName + " was successfully created");

    } catch (GlueException e) {
        throw e;
    }
}

/**
 * Retrieves a specific crawler from the AWS Glue service and waits for it to
 * be in the "READY" state.
 *
 * @param glueClient the AWS Glue client used to interact with the Glue
 * service
 * @param crawlerName the name of the crawler to be retrieved
 */
public static void getSpecificCrawler(GlueClient glueClient, String
crawlerName) throws InterruptedException {
    try {
        GetCrawlerRequest crawlerRequest = GetCrawlerRequest.builder()
            .name(crawlerName)
            .build();

        boolean ready = false;

```



```

        while (!ready) {
            GetCrawlerResponse response =
glueClient.getCrawler(crawlerRequest);
            String status = response.crawler().stateAsString();
            if (status.compareTo("READY") == 0) {
                ready = true;
            }
            Thread.sleep(3000);
        }

        System.out.println("The crawler is now ready");

    } catch (GlueException | InterruptedException e) {
        throw e;
    }
}

/**
 * Starts a specific AWS Glue crawler.
 *
 * @param glueClient the AWS Glue client to use for the crawler operation
 * @param crawlerName the name of the crawler to start
 * @throws GlueException if there is an error starting the crawler
 */
public static void startSpecificCrawler(GlueClient glueClient, String
crawlerName) {
    try {
        StartCrawlerRequest crawlerRequest = StartCrawlerRequest.builder()
            .name(crawlerName)
            .build();

        glueClient.startCrawler(crawlerRequest);
        System.out.println(crawlerName + " was successfully started!");

    } catch (GlueException e) {
        throw e;
    }
}

/**
 * Retrieves the specific database from the AWS Glue service.
 *
 * @param glueClient an instance of the AWS Glue client used to interact
with the service

```

```

    * @param dbName the name of the database to retrieve
    * @throws GlueException if there is an error retrieving the database from
the AWS Glue service
    */
    public static void getSpecificDatabase(GlueClient glueClient, String
dbName) {
        try {
            GetDatabaseRequest databasesRequest = GetDatabaseRequest.builder()
                .name(dbName)
                .build();

            GetDatabaseResponse response =
glueClient.getDatabase(databasesRequest);
            Instant createDate = response.database().createTime();

            // Convert the Instant to readable date.
            DateTimeFormatter formatter =
DateTimeFormatter.ofLocalizedDateTime(FormatStyle.SHORT)
                .withLocale(Locale.US)
                .withZone(ZoneId.systemDefault());

            formatter.format(createDate);
            System.out.println("The create date of the database is " +
createDate);

        } catch (GlueException e) {
            throw e;
        }
    }

    /**
    * Retrieves the names of the tables in the specified Glue database.
    *
    * @param glueClient the Glue client to use for the operation
    * @param dbName the name of the Glue database to retrieve the table
names from
    * @return the name of the first table retrieved, or an empty string if no
tables were found
    */
    public static String getGlueTables(GlueClient glueClient, String dbName) {
        String myTableName = "";
        try {
            GetTablesRequest tableRequest = GetTablesRequest.builder()

```

```

        .databaseName(dbName)
        .build();

    GetTablesResponse response = glueClient.getTables(tableRequest);
    List<Table> tables = response.tableList();
    if (tables.isEmpty()) {
        System.out.println("No tables were returned");
    } else {
        for (Table table : tables) {
            myTableName = table.name();
            System.out.println("Table name is: " + myTableName);
        }
    }

} catch (GlueException e) {
    throw e;
}
return myTableName;
}

/**
 * Starts a job run in AWS Glue.
 *
 * @param glueClient    the AWS Glue client to use for the job run
 * @param jobName       the name of the Glue job to run
 * @param inputDatabase the name of the input database
 * @param inputTable    the name of the input table
 * @param outBucket     the URL of the output S3 bucket
 * @throws GlueException if there is an error starting the job run
 */
public static void startJob(GlueClient glueClient, String jobName, String
inputDatabase, String inputTable,
                           String outBucket) {
    try {
        Map<String, String> myMap = new HashMap<>();
        myMap.put("--input_database", inputDatabase);
        myMap.put("--input_table", inputTable);
        myMap.put("--output_bucket_url", outBucket);

        StartJobRunRequest runRequest = StartJobRunRequest.builder()
            .workerType(WorkerType.G_1_X)
            .numberOfWorkers(10)
            .arguments(myMap)

```

```
        .jobName(jobName)
        .build();

        StartJobRunResponse response = glueClient.startJobRun(runRequest);
        System.out.println("The request Id of the job is " +
response.responseMetadata().requestId());

    } catch (GlueException e) {
        throw e;
    }
}

/**
 * Creates a new AWS Glue job.
 *
 * @param glueClient    the AWS Glue client to use for the operation
 * @param jobName       the name of the job to create
 * @param iam           the IAM role to associate with the job
 * @param scriptLocation the location of the script to be used by the job
 * @throws GlueException if there is an error creating the job
 */
public static void createJob(GlueClient glueClient, String jobName, String
iam, String scriptLocation) {
    try {
        JobCommand command = JobCommand.builder()
            .pythonVersion("3")
            .name("glueetl")
            .scriptLocation(scriptLocation)
            .build();

        CreateJobRequest jobRequest = CreateJobRequest.builder()
            .description("A Job created by using the AWS SDK for Java V2")
            .glueVersion("2.0")
            .workerType(WorkerType.G_1_X)
            .numberOfWorkers(10)
            .name(jobName)
            .role(iam)
            .command(command)
            .build();

        glueClient.createJob(jobRequest);
        System.out.println(jobName + " was successfully created.");
    }
```

```

        } catch (GlueException e) {
            throw e;
        }
    }

    /**
     * Retrieves and prints information about all the jobs in the Glue data
     catalog.
     *
     * @param glueClient the Glue client used to interact with the AWS Glue
     service
     */
    public static void getAllJobs(GlueClient glueClient) {
        try {
            GetJobsRequest jobsRequest = GetJobsRequest.builder()
                .maxResults(10)
                .build();

            GetJobsResponse jobsResponse = glueClient.getJobs(jobsRequest);
            List<Job> jobs = jobsResponse.jobs();
            for (Job job : jobs) {
                System.out.println("Job name is : " + job.name());
                System.out.println("The job worker type is : " +
job.workerType().name());
            }

        } catch (GlueException e) {
            throw e;
        }
    }

    /**
     * Retrieves the job runs for a given Glue job and prints the status of the
     job runs.
     *
     * @param glueClient the Glue client used to make API calls
     * @param jobName    the name of the Glue job to retrieve the job runs for
     */
    public static void getJobRuns(GlueClient glueClient, String jobName) {
        try {
            GetJobRunsRequest runsRequest = GetJobRunsRequest.builder()
                .jobName(jobName)
                .maxResults(20)

```

```

        .build();

        boolean jobDone = false;
        while (!jobDone) {
            GetJobRunsResponse response = glueClient.getJobRuns(runsRequest);
            List<JobRun> jobRuns = response.jobRuns();
            for (JobRun jobRun : jobRuns) {
                String jobState = jobRun.jobRunState().name();
                if (jobState.compareTo("SUCCEEDED") == 0) {
                    System.out.println(jobName + " has succeeded");
                    jobDone = true;

                } else if (jobState.compareTo("STOPPED") == 0) {
                    System.out.println("Job run has stopped");
                    jobDone = true;

                } else if (jobState.compareTo("FAILED") == 0) {
                    System.out.println("Job run has failed");
                    jobDone = true;

                } else if (jobState.compareTo("TIMEOUT") == 0) {
                    System.out.println("Job run has timed out");
                    jobDone = true;

                } else {
                    System.out.println("*** Job run state is " +
jobRun.jobRunState().name());
                    System.out.println("Job run Id is " + jobRun.id());
                    System.out.println("The Glue version is " +
jobRun.glueVersion());
                }
                TimeUnit.SECONDS.sleep(5);
            }
        }

        } catch (GlueException e) {
            throw e;
        } catch (InterruptedException e) {
            throw new RuntimeException(e);
        }
    }

    /**

```

```
* Deletes a Glue job.
*
* @param glueClient the Glue client to use for the operation
* @param jobName the name of the job to be deleted
* @throws GlueException if there is an error deleting the job
*/
public static void deleteJob(GlueClient glueClient, String jobName) {
    try {
        DeleteJobRequest jobRequest = DeleteJobRequest.builder()
            .jobName(jobName)
            .build();

        glueClient.deleteJob(jobRequest);
        System.out.println(jobName + " was successfully deleted");

    } catch (GlueException e) {
        throw e;
    }
}

/**
 * Deletes a AWS Glue Database.
 *
 * @param glueClient An instance of the AWS Glue client used to interact
with the AWS Glue service.
 * @param databaseName The name of the database to be deleted.
 * @throws GlueException If an error occurs while deleting the database.
 */
public static void deleteDatabase(GlueClient glueClient, String databaseName)
{
    try {
        DeleteDatabaseRequest request = DeleteDatabaseRequest.builder()
            .name(databaseName)
            .build();

        glueClient.deleteDatabase(request);
        System.out.println(databaseName + " was successfully deleted");

    } catch (GlueException e) {
        throw e;
    }
}
```

```
/**
 * Deletes a specific AWS Glue crawler.
 *
 * @param glueClient the AWS Glue client object
 * @param crawlerName the name of the crawler to be deleted
 * @throws GlueException if an error occurs during the deletion process
 */
public static void deleteSpecificCrawler(GlueClient glueClient, String
crawlerName) {
    try {
        DeleteCrawlerRequest deleteCrawlerRequest =
DeleteCrawlerRequest.builder()
            .name(crawlerName)
            .build();

        glueClient.deleteCrawler(deleteCrawlerRequest);
        System.out.println(crawlerName + " was deleted");

    } catch (GlueException e) {
        throw e;
    }
}

private static void waitForInputToContinue(Scanner scanner) {
    while (true) {
        System.out.println("");
        System.out.println("Enter 'c' followed by <ENTER> to continue:");
        String input = scanner.nextLine();

        if (input.trim().equalsIgnoreCase("c")) {
            System.out.println("Continuing with the program...");
            System.out.println("");
            break;
        } else {
            // Handle invalid input.
            System.out.println("Invalid input. Please try again.");
        }
    }
}
}
```


- Pour plus d'informations sur l'API, consultez les rubriques suivantes dans la référence de l'API AWS SDK for Java 2.x .
 - [CreateCrawler](#)
 - [CreateJob](#)
 - [DeleteCrawler](#)
 - [DeleteDatabase](#)
 - [DeleteJob](#)
 - [DeleteTable](#)
 - [GetCrawler](#)
 - [GetDatabase](#)
 - [GetDatabases](#)
 - [GetJob](#)
 - [GetJobRun](#)
 - [GetJobRuns](#)
 - [GetTables](#)
 - [ListJobs](#)
 - [StartCrawler](#)
 - [StartJobRun](#)

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

Créez et exécutez un crawler qui analyse un compartiment Amazon Simple Storage Service (Amazon S3) public et génère une base de données de métadonnées qui décrit les données au format CSV trouvées.

```
const createCrawler = (name, role, dbName, tablePrefix, s3TargetPath) => {
```

```
const client = new GlueClient({});

const command = new CreateCrawlerCommand({
  Name: name,
  Role: role,
  DatabaseName: dbName,
  TablePrefix: tablePrefix,
  Targets: {
    S3Targets: [{ Path: s3TargetPath }],
  },
});

return client.send(command);
};

const getCrawler = (name) => {
  const client = new GlueClient({});

  const command = new GetCrawlerCommand({
    Name: name,
  });

  return client.send(command);
};

const startCrawler = (name) => {
  const client = new GlueClient({});

  const command = new StartCrawlerCommand({
    Name: name,
  });

  return client.send(command);
};

const crawlerExists = async ({ getCrawler }, crawlerName) => {
  try {
    await getCrawler(crawlerName);
    return true;
  } catch {
    return false;
  }
};
```

```

/**
 * @param {{ createCrawler: import('../../actions/create-
crawler.js').createCrawler}} actions
 */
const makeCreateCrawlerStep = (actions) => async (context) => {
  if (await crawlerExists(actions, process.env.CRAWLER_NAME)) {
    log("Crawler already exists. Skipping creation.");
  } else {
    await actions.createCrawler(
      process.env.CRAWLER_NAME,
      process.env.ROLE_NAME,
      process.env.DATABASE_NAME,
      process.env.TABLE_PREFIX,
      process.env.S3_TARGET_PATH,
    );

    log("Crawler created successfully.", { type: "success" });
  }

  return { ...context };
};

/**
 * @param {(name: string) => Promise<import('@aws-sdk/client-
glue').GetCrawlerCommandOutput>} getCrawler
 * @param {string} crawlerName
 */
const waitForCrawler = async (getCrawler, crawlerName) => {
  const waitTimeInSeconds = 30;
  const { Crawler } = await getCrawler(crawlerName);

  if (!Crawler) {
    throw new Error(`Crawler with name ${crawlerName} not found.`);
  }

  if (Crawler.State === "READY") {
    return;
  }

  log(`Crawler is ${Crawler.State}. Waiting ${waitTimeInSeconds} seconds...`);
  await wait(waitTimeInSeconds);
  return waitForCrawler(getCrawler, crawlerName);
};

```

```
const makeStartCrawlerStep =
  ({ startCrawler, getCrawler }) =>
  async (context) => {
    log("Starting crawler.");
    await startCrawler(process.env.CRAWLER_NAME);
    log("Crawler started.", { type: "success" });

    log("Waiting for crawler to finish running. This can take a while.");
    await waitForCrawler(getCrawler, process.env.CRAWLER_NAME);
    log("Crawler ready.", { type: "success" });

    return { ...context };
  };
```

Répertoriez les informations relatives aux bases de données et aux tables de votre AWS Glue Data Catalog.

```
const getDatabase = (name) => {
  const client = new GlueClient({});

  const command = new GetDatabaseCommand({
    Name: name,
  });

  return client.send(command);
};

const getTables = (databaseName) => {
  const client = new GlueClient({});

  const command = new GetTablesCommand({
    DatabaseName: databaseName,
  });

  return client.send(command);
};

const makeGetDatabaseStep =
  ({ getDatabase }) =>
  async (context) => {
    const {
      Database: { Name },
    } = await getDatabase(Name);
  };
```

```

    } = await getDatabase(process.env.DATABASE_NAME);
    log(`Database: ${Name}`);
    return { ...context };
  };

/**
 * @param {{ getTables: () => Promise<import('@aws-sdk/client-glue').GetTablesCommandOutput>}} config
 */
const makeGetTablesStep =
  ({ getTables }) => {
    async (context) => {
      const { TableList } = await getTables(process.env.DATABASE_NAME);
      log("Tables:");
      log(TableList.map((table) => `    • ${table.Name}\n`));
      return { ...context };
    };
  };

```

Créez et exécutez une tâche qui extrait les données CSV du compartiment Amazon S3 source, les transforme en supprimant et en renommant des champs, et charge la sortie au format JSON dans un autre compartiment Amazon S3.

```

const createJob = (name, role, scriptBucketName, scriptKey) => {
  const client = new GlueClient({});

  const command = new CreateJobCommand({
    Name: name,
    Role: role,
    Command: {
      Name: "glueetl",
      PythonVersion: "3",
      ScriptLocation: `s3://${scriptBucketName}/${scriptKey}`,
    },
    GlueVersion: "3.0",
  });

  return client.send(command);
};

const startJobRun = (jobName, dbName, tableName, bucketName) => {
  const client = new GlueClient({});

```

```

const command = new StartJobRunCommand({
  JobName: jobName,
  Arguments: {
    "--input_database": dbName,
    "--input_table": tableName,
    "--output_bucket_url": `s3://${bucketName}/`,
  },
});

return client.send(command);
};

const makeCreateJobStep =
  ({ createJob }) =>
  async (context) => {
    log("Creating Job.");
    await createJob(
      process.env.JOB_NAME,
      process.env.ROLE_NAME,
      process.env.BUCKET_NAME,
      process.env.PYTHON_SCRIPT_KEY,
    );
    log("Job created.", { type: "success" });

    return { ...context };
  };

/**
 * @param {(name: string, runId: string) => Promise<import('@aws-sdk/client-glue').GetJobRunCommandOutput> } getJobRun
 * @param {string} jobName
 * @param {string} jobRunId
 */
const waitForJobRun = async (getJobRun, jobName, jobRunId) => {
  const waitTimeInSeconds = 30;
  const { JobRun } = await getJobRun(jobName, jobRunId);

  if (!JobRun) {
    throw new Error(`Job run with id ${jobRunId} not found.`);
  }

  switch (JobRun.JobRunState) {
    case "FAILED":
    case "TIMEOUT":

```

```

    case "STOPPED":
    case "ERROR":
        throw new Error(
            `Job ${JobRun.JobRunState}. Error: ${JobRun.ErrorMessage}`,
        );
    case "SUCCEEDED":
        return;
    default:
        break;
}

log(
    `Job ${JobRun.JobRunState}. Waiting ${waitTimeInSeconds} more seconds...`,
);
await wait(waitTimeInSeconds);
return waitForJobRun(getJobRun, jobName, jobRunId);
};

/**
 * @param {{ prompter: { prompt: () => Promise<{ shouldOpen: boolean }>} }}
 * context
 */
const promptToOpen = async (context) => {
    const { shouldOpen } = await context.prompter.prompt({
        name: "shouldOpen",
        type: "confirm",
        message: "Open the output bucket in your browser?",
    });

    if (shouldOpen) {
        return open(
            `https://s3.console.aws.amazon.com/s3/buckets/${process.env.BUCKET_NAME} to
            view the output.`,
        );
    }
};

const makeStartJobRunStep =
    ({ startJobRun, getJobRun }) =>
    async (context) => {
        log("Starting job.");
        const { JobRunId } = await startJobRun(
            process.env.JOB_NAME,
            process.env.DATABASE_NAME,

```

```

        process.env.TABLE_NAME,
        process.env.BUCKET_NAME,
    );
    log("Job started.", { type: "success" });

    log("Waiting for job to finish running. This can take a while.");
    await waitForJobRun(getJobRun, process.env.JOB_NAME, JobRunId);
    log("Job run succeeded.", { type: "success" });

    await promptToOpen(context);

    return { ...context };
};

```

Répertoriez les informations relatives aux exécutions de tâches et affichez certaines des données transformées.

```

const getJobRuns = (jobName) => {
    const client = new GlueClient({});
    const command = new GetJobRunsCommand({
        JobName: jobName,
    });

    return client.send(command);
};

const getJobRun = (jobName, jobRunId) => {
    const client = new GlueClient({});
    const command = new GetJobRunCommand({
        JobName: jobName,
        RunId: jobRunId,
    });

    return client.send(command);
};

/**
 * @typedef {{ prompter: { prompt: () => Promise<{jobName: string}> } }} Context
 */

/**

```



```

    * @typedef {() => Promise<import('@aws-sdk/client-
glue').GetJobRunCommandOutput>} getJobRun
    */

/**
    * @typedef {() => Promise<import('@aws-sdk/client-
glue').GetJobRunsCommandOutput>} getJobRuns
    */

/**
    *
    * @param {getJobRun} getJobRun
    * @param {string} jobName
    * @param {string} jobRunId
    */
const logJobRunDetails = async (getJobRun, jobName, jobRunId) => {
    const { JobRun } = await getJobRun(jobName, jobRunId);
    log(JobRun, { type: "object" });
};

/**
    *
    * @param {{getJobRuns: getJobRuns, getJobRun: getJobRun }} funcs
    */
const makePickJobRunStep =
    ({ getJobRuns, getJobRun }) =>
    async (** @type { Context } */ context) => {
        if (context.selectedJobName) {
            const { JobRuns } = await getJobRuns(context.selectedJobName);

            const { jobRunId } = await context.prompter.prompt({
                name: "jobRunId",
                type: "list",
                message: "Select a job run to see details.",
                choices: JobRuns.map((run) => run.Id),
            });

            logJobRunDetails(getJobRun, context.selectedJobName, jobRunId);
        }

        return { ...context };
    };

```

Supprimez toutes les ressources créées par la démonstration.

```
const deleteJob = (jobName) => {
  const client = new GlueClient({});

  const command = new DeleteJobCommand({
    JobName: jobName,
  });

  return client.send(command);
};

const deleteTable = (databaseName, tableName) => {
  const client = new GlueClient({});

  const command = new DeleteTableCommand({
    DatabaseName: databaseName,
    Name: tableName,
  });

  return client.send(command);
};

const deleteDatabase = (databaseName) => {
  const client = new GlueClient({});

  const command = new DeleteDatabaseCommand({
    Name: databaseName,
  });

  return client.send(command);
};

const deleteCrawler = (crawlerName) => {
  const client = new GlueClient({});

  const command = new DeleteCrawlerCommand({
    Name: crawlerName,
  });

  return client.send(command);
};

/**
```

```

*
* @param {import('../../../actions/delete-job.js').deleteJob} deleteJobFn
* @param {string[]} jobNames
* @param {{ prompter: { prompt: () => Promise<any> }}} context
*/
const handleDeleteJobs = async (deleteJobFn, jobNames, context) => {
  /**
   * @type {{ selectedJobNames: string[] }}
   */
  const { selectedJobNames } = await context.prompter.prompt({
    name: "selectedJobNames",
    type: "checkbox",
    message: "Let's clean up jobs. Select jobs to delete.",
    choices: jobNames,
  });

  if (selectedJobNames.length === 0) {
    log("No jobs selected.");
  } else {
    log("Deleting jobs.");
    await Promise.all(
      selectedJobNames.map((n) => deleteJobFn(n).catch(console.error)),
    );
    log("Jobs deleted.", { type: "success" });
  }
};

/**
 * @param {{
 *   listJobs: import('../../../actions/list-jobs.js').listJobs,
 *   deleteJob: import('../../../actions/delete-job.js').deleteJob
 * }} config
 */
const makeCleanUpJobsStep =
  ({ listJobs, deleteJob }) =>
  async (context) => {
    const { JobNames } = await listJobs();
    if (JobNames.length > 0) {
      await handleDeleteJobs(deleteJob, JobNames, context);
    }

    return { ...context };
  };

```

```

/**
 * @param {import('../../../actions/delete-table.js').deleteTable} deleteTable
 * @param {string} databaseName
 * @param {string[]} tableNames
 */
const deleteTables = (deleteTable, databaseName, tableNames) =>
  Promise.all(
    tableNames.map((tableName) =>
      deleteTable(databaseName, tableName).catch(console.error),
    ),
  );

/**
 * @param {{
 *   getTables: import('../../../actions/get-tables.js').getTables,
 *   deleteTable: import('../../../actions/delete-table.js').deleteTable
 * }} config
 */
const makeCleanUpTablesStep =
  ({ getTables, deleteTable }) =>
  /**
   * @param {{ prompter: { prompt: () => Promise<any>}}} context
   */
  async (context) => {
    const { TableList } = await getTables(process.env.DATABASE_NAME).catch(
      () => ({ TableList: null }),
    );

    if (TableList && TableList.length > 0) {
      /**
       * @type {{ tableNames: string[] }}
       */
      const { tableNames } = await context.prompter.prompt({
        name: "tableNames",
        type: "checkbox",
        message: "Let's clean up tables. Select tables to delete.",
        choices: TableList.map((t) => t.Name),
      });

      if (tableNames.length === 0) {
        log("No tables selected.");
      } else {
        log("Deleting tables.");
        await deleteTables(deleteTable, process.env.DATABASE_NAME, tableNames);
      }
    }
  }

```

```

        log("Tables deleted.", { type: "success" });
    }
}

return { ...context };
};

/**
 * @param {import('../../actions/delete-database.js').deleteDatabase}
deleteDatabase
 * @param {string[]} databaseNames
 */
const deleteDatabases = (deleteDatabase, databaseNames) =>
    Promise.all(
        databaseNames.map((dbName) => deleteDatabase(dbName).catch(console.error)),
    );

/**
 * @param {{
 *   getDatabases: import('../../actions/get-databases.js').getDatabases
 *   deleteDatabase: import('../../actions/delete-database.js').deleteDatabase
 * }} config
 */
const makeCleanUpDatabasesStep =
    ({ getDatabases, deleteDatabase }) =>
    /**
     * @param {{ prompter: { prompt: () => Promise<any> } } } context
     */
    async (context) => {
        const { DatabaseList } = await getDatabases();

        if (DatabaseList.length > 0) {
            /** @type {{ dbNames: string[] }} */
            const { dbNames } = await context.prompter.prompt({
                name: "dbNames",
                type: "checkbox",
                message: "Let's clean up databases. Select databases to delete.",
                choices: DatabaseList.map((db) => db.Name),
            });

            if (dbNames.length === 0) {
                log("No databases selected.");
            } else {
                log("Deleting databases.");
            }
        }
    }
}

```

```
        await deleteDatabases(deleteDatabase, dbName);
        log("Databases deleted.", { type: "success" });
    }
}

return { ...context };
};

const cleanUpCrawlerStep = async (context) => {
    log("Deleting crawler.");

    try {
        await deleteCrawler(process.env.CRAWLER_NAME);
        log("Crawler deleted.", { type: "success" });
    } catch (err) {
        if (err.name === "EntityNotFoundException") {
            log("Crawler is already deleted.");
        } else {
            throw err;
        }
    }

    return { ...context };
};
```

- Pour plus d'informations sur l'API consultez les rubriques suivantes dans la référence de l'API AWS SDK pour JavaScript .
 - [CreateCrawler](#)
 - [CreateJob](#)
 - [DeleteCrawler](#)
 - [DeleteDatabase](#)
 - [DeleteJob](#)
 - [DeleteTable](#)
 - [GetCrawler](#)
 - [GetDatabase](#)
 - [GetDatabases](#)
 - [GetJob](#)
 - [GetJobRun](#)

- [GetJobRuns](#)
- [GetTables](#)
- [ListJobs](#)
- [StartCrawler](#)
- [StartJobRun](#)

Kotlin

SDK pour Kotlin

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
suspend fun main(args: Array<String>) {
    val usage = """
        Usage:
            <iam> <s3Path> <cron> <dbName> <crawlerName> <jobName>
            <scriptLocation> <locationUri>

        Where:
            iam - The Amazon Resource Name (ARN) of the AWS Identity and Access
            Management (IAM) role that has AWS Glue and Amazon Simple Storage Service
            (Amazon S3) permissions.
            s3Path - The Amazon Simple Storage Service (Amazon S3) target that
            contains data (for example, CSV data).
            cron - A cron expression used to specify the schedule (for example,
            cron(15 12 * * ? *).
            dbName - The database name.
            crawlerName - The name of the crawler.
            jobName - The name you assign to this job definition.
            scriptLocation - Specifies the Amazon S3 path to a script that runs a
            job.
            locationUri - Specifies the location of the database
        """

    if (args.size != 8) {
        println(usage)
    }
}
```

```

        exitProcess(1)
    }

    val iam = args[0]
    val s3Path = args[1]
    val cron = args[2]
    val dbName = args[3]
    val crawlerName = args[4]
    val jobName = args[5]
    val scriptLocation = args[6]
    val locationUri = args[7]

    println("About to start the AWS Glue Scenario")
    createDatabase(dbName, locationUri)
    createCrawler(iam, s3Path, cron, dbName, crawlerName)
    getCrawler(crawlerName)
    startCrawler(crawlerName)
    getDatabase(dbName)
    getGlueTables(dbName)
    createJob(jobName, iam, scriptLocation)
    startJob(jobName)
    getJobs()
    getJobRuns(jobName)
    deleteJob(jobName)
    println("*** Wait for 5 MIN so the $crawlerName is ready to be deleted")
    TimeUnit.MINUTES.sleep(5)
    deleteMyDatabase(dbName)
    deleteCrawler(crawlerName)
}

suspend fun createDatabase(
    dbName: String?,
    locationUriVal: String?,
) {
    val input =
        DatabaseInput {
            description = "Built with the AWS SDK for Kotlin"
            name = dbName
            locationUri = locationUriVal
        }

    val request =
        CreateDatabaseRequest {
            databaseInput = input

```



```
    }

    GlueClient { region = "us-east-1" }.use { glueClient ->
        glueClient.createDatabase(request)
        println("The database was successfully created")
    }
}

suspend fun createCrawler(
    iam: String?,
    s3Path: String?,
    cron: String?,
    dbName: String?,
    crawlerName: String,
) {
    val s3Target =
        S3Target {
            path = s3Path
        }

    val targetList = ArrayList<S3Target>()
    targetList.add(s3Target)

    val target0b =
        CrawlerTargets {
            s3Targets = targetList
        }

    val crawlerRequest =
        CreateCrawlerRequest {
            databaseName = dbName
            name = crawlerName
            description = "Created by the AWS Glue Java API"
            targets = target0b
            role = iam
            schedule = cron
        }

    GlueClient { region = "us-east-1" }.use { glueClient ->
        glueClient.createCrawler(crawlerRequest)
        println("$crawlerName was successfully created")
    }
}
```

```
suspend fun getCrawler(crawlerName: String?) {
    val request =
        GetCrawlerRequest {
            name = crawlerName
        }

    GlueClient { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.getCrawler(request)
        val role = response.crawler?.role
        println("The role associated with this crawler is $role")
    }
}

suspend fun startCrawler(crawlerName: String) {
    val crawlerRequest =
        StartCrawlerRequest {
            name = crawlerName
        }

    GlueClient { region = "us-east-1" }.use { glueClient ->
        glueClient.startCrawler(crawlerRequest)
        println("$crawlerName was successfully started.")
    }
}

suspend fun getDatabase(databaseName: String?) {
    val request =
        GetDatabaseRequest {
            name = databaseName
        }

    GlueClient { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.getDatabase(request)
        val dbDesc = response.database?.description
        println("The database description is $dbDesc")
    }
}

suspend fun getGlueTables(dbName: String?) {
    val tableRequest =
        GetTablesRequest {
            databaseName = dbName
        }
}
```

```
GlueClient { region = "us-east-1" }.use { glueClient ->
    val response = glueClient.getTables(tableRequest)
    response.tableList?.forEach { tableName ->
        println("Table name is ${tableName.name}")
    }
}

suspend fun startJob(jobNameVal: String?) {
    val runRequest =
        StartJobRunRequest {
            workerType = WorkerType.G1X
            numberOfWorkers = 10
            jobName = jobNameVal
        }

    GlueClient { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.startJobRun(runRequest)
        println("The job run Id is ${response.jobRunId}")
    }
}

suspend fun createJob(
    jobName: String,
    iam: String?,
    scriptLocationVal: String?,
) {
    val command0b =
        JobCommand {
            pythonVersion = "3"
            name = "MyJob1"
            scriptLocation = scriptLocationVal
        }

    val jobRequest =
        CreateJobRequest {
            description = "A Job created by using the AWS SDK for Java V2"
            glueVersion = "2.0"
            workerType = WorkerType.G1X
            numberOfWorkers = 10
            name = jobName
            role = iam
            command = command0b
        }
}
```

```
        GlueClient { region = "us-east-1" }.use { glueClient ->
            glueClient.createJob(jobRequest)
            println("$jobName was successfully created.")
        }
    }

suspend fun getJobs() {
    val request =
        GetJobsRequest {
            maxResults = 10
        }

    GlueClient { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.getJobs(request)
        response.jobs?.forEach { job ->
            println("Job name is ${job.name}")
        }
    }
}

suspend fun getJobRuns(jobNameVal: String?) {
    val request =
        GetJobRunsRequest {
            jobName = jobNameVal
        }

    GlueClient { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.getJobRuns(request)
        response.jobRuns?.forEach { job ->
            println("Job name is ${job.jobName}")
        }
    }
}

suspend fun deleteJob(jobNameVal: String) {
    val jobRequest =
        DeleteJobRequest {
            jobName = jobNameVal
        }

    GlueClient { region = "us-east-1" }.use { glueClient ->
        glueClient.deleteJob(jobRequest)
        println("$jobNameVal was successfully deleted")
    }
}
```

```
    }  
}  
  
suspend fun deleteMyDatabase(databaseName: String) {  
    val request =  
        DeleteDatabaseRequest {  
            name = databaseName  
        }  
  
    GlueClient { region = "us-east-1" }.use { glueClient ->  
        glueClient.deleteDatabase(request)  
        println("$databaseName was successfully deleted")  
    }  
}  
  
suspend fun deleteCrawler(crawlerName: String) {  
    val request =  
        DeleteCrawlerRequest {  
            name = crawlerName  
        }  
  
    GlueClient { region = "us-east-1" }.use { glueClient ->  
        glueClient.deleteCrawler(request)  
        println("$crawlerName was deleted")  
    }  
}
```

- Pour plus d'informations sur l'API, consultez les rubriques suivantes dans AWS SDK for Kotlin API reference.
 - [CreateCrawler](#)
 - [CreateJob](#)
 - [DeleteCrawler](#)
 - [DeleteDatabase](#)
 - [DeleteJob](#)
 - [DeleteTable](#)
 - [GetCrawler](#)
 - [GetDatabase](#)
 - [GetDatabases](#)
 - [GetJob](#)

- [GetJobRun](#)
- [GetJobRuns](#)
- [GetTables](#)
- [ListJobs](#)
- [StartCrawler](#)
- [StartJobRun](#)

PHP

Kit SDK pour PHP

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
namespace Glue;

use Aws\Glue\GlueClient;
use Aws\S3\S3Client;
use AwsUtilities\AWSServiceClass;
use GuzzleHttp\Psr7\Stream;
use Iam\IAMService;

class GettingStartedWithGlue
{
    public function run()
    {
        echo("\n");
        echo("-----\n");
        print("Welcome to the AWS Glue getting started demo using PHP!\n");
        echo("-----\n");

        $clientArgs = [
            'region' => 'us-west-2',
            'version' => 'latest',
            'profile' => 'default',
        ];
    }
}
```

```
$uniqid = uniqid();

$glueClient = new GlueClient($clientArgs);
$glueService = new GlueService($glueClient);
$iamService = new IAMService();
$crawlerName = "example-crawler-test-" . $uniqid;

AWSServiceClass::$waitTime = 5;
AWSServiceClass::$maxWaitAttempts = 20;

$role = $iamService->getRole("AWSGlueServiceRole-DocExample");

$databaseName = "doc-example-database-$uniqid";
$path = 's3://crawler-public-us-east-1/flight/2016/csv';
$glueService->createCrawler($crawlerName, $role['Role']['Arn'],
$databaseName, $path);
$glueService->startCrawler($crawlerName);

echo "Waiting for crawler";
do {
    $crawler = $glueService->getCrawler($crawlerName);
    echo ".";
    sleep(10);
} while ($crawler['Crawler']['State'] != "READY");
echo "\n";

$database = $glueService->getDatabase($databaseName);
echo "Found a database named " . $database['Database']['Name'] . "\n";

//Upload job script
$s3client = new S3Client($clientArgs);
$bucketName = "test-glue-bucket-" . $uniqid;
$s3client->createBucket([
    'Bucket' => $bucketName,
    'CreateBucketConfiguration' => ['LocationConstraint' => 'us-west-2'],
]);

$s3client->putObject([
    'Bucket' => $bucketName,
    'Key' => 'run_job.py',
    'SourceFile' => __DIR__ . '/flight_etl_job_script.py'
]);
$s3client->putObject([
    'Bucket' => $bucketName,
```

```

        'Key' => 'setup_scenario_getting_started.yaml',
        'SourceFile' => __DIR__ . '/setup_scenario_getting_started.yaml'
    ]);

    $tables = $glueService->getTables($databaseName);

    $jobName = 'test-job-' . $uniqid;
    $scriptLocation = "s3://$bucketName/run_job.py";
    $job = $glueService->createJob($jobName, $role['Role']['Arn'],
    $scriptLocation);

    $outputBucketUrl = "s3://$bucketName";
    $runId = $glueService->startJobRun($jobName, $databaseName, $tables,
    $outputBucketUrl)['JobRunId'];

    echo "waiting for job";
    do {
        $jobRun = $glueService->getJobRun($jobName, $runId);
        echo ".";
        sleep(10);
    } while (!array_intersect([$jobRun['JobRun']['JobRunState']],
    ['SUCCEEDED', 'STOPPED', 'FAILED', 'TIMEOUT']));
    echo "\n";

    $jobRuns = $glueService->getJobRuns($jobName);

    $objects = $s3client->listObjects([
        'Bucket' => $bucketName,
    ]['Contents']);

    foreach ($objects as $object) {
        echo $object['Key'] . "\n";
    }

    echo "Downloading " . $objects[1]['Key'] . "\n";
    /** @var Stream $downloadObject */
    $downloadObject = $s3client->getObject([
        'Bucket' => $bucketName,
        'Key' => $objects[1]['Key'],
    ]['Body']->getContents());
    echo "Here is the first 1000 characters in the object.";
    echo substr($downloadObject, 0, 1000);

    $jobs = $glueService->listJobs();

```



```

        echo "Current jobs:\n";
        foreach ($jobs['JobNames'] as $jobsName) {
            echo "{$jobsName}\n";
        }

        echo "Delete the job.\n";
        $glueClient->deleteJob([
            'JobName' => $job['Name'],
        ]);

        echo "Delete the tables.\n";
        foreach ($tables['TableList'] as $table) {
            $glueService->deleteTable($table['Name'], $databaseName);
        }

        echo "Delete the databases.\n";
        $glueClient->deleteDatabase([
            'Name' => $databaseName,
        ]);

        echo "Delete the crawler.\n";
        $glueClient->deleteCrawler([
            'Name' => $crawlerName,
        ]);

        $deleteObjects = $s3client->listObjectsV2([
            'Bucket' => $bucketName,
        ]);
        echo "Delete all objects in the bucket.\n";
        $deleteObjects = $s3client->deleteObjects([
            'Bucket' => $bucketName,
            'Delete' => [
                'Objects' => $deleteObjects['Contents'],
            ]
        ]);
        echo "Delete the bucket.\n";
        $s3client->deleteBucket(['Bucket' => $bucketName]);

        echo "This job was brought to you by the number $uniqid\n";
    }
}

namespace Glue;

```

```

use Aws\Glue\GlueClient;
use Aws\Result;

use function PHPUnit\Framework\isEmpty;

class GlueService extends \AwsUtilities\AWSServiceClass
{
    protected GlueClient $glueClient;

    public function __construct($glueClient)
    {
        $this->glueClient = $glueClient;
    }

    public function getCrawler($crawlerName)
    {
        return $this->customWaiter(function () use ($crawlerName) {
            return $this->glueClient->getCrawler([
                'Name' => $crawlerName,
            ]);
        });
    }

    public function createCrawler($crawlerName, $role, $databaseName, $path):
    Result
    {
        return $this->customWaiter(function () use ($crawlerName, $role,
        $databaseName, $path) {
            return $this->glueClient->createCrawler([
                'Name' => $crawlerName,
                'Role' => $role,
                'DatabaseName' => $databaseName,
                'Targets' => [
                    'S3Targets' =>
                        [[
                            'Path' => $path,
                        ]],
                ],
            ]);
        });
    }

    public function startCrawler($crawlerName): Result
    {

```

```

        return $this->glueClient->startCrawler([
            'Name' => $crawlerName,
        ]);
    }

    public function getDatabase(string $databaseName): Result
    {
        return $this->customWaiter(function () use ($databaseName) {
            return $this->glueClient->getDatabase([
                'Name' => $databaseName,
            ]);
        });
    }

    public function getTables($databaseName): Result
    {
        return $this->glueClient->getTables([
            'DatabaseName' => $databaseName,
        ]);
    }

    public function createJob($jobName, $role, $scriptLocation, $pythonVersion =
'3', $glueVersion = '3.0'): Result
    {
        return $this->glueClient->createJob([
            'Name' => $jobName,
            'Role' => $role,
            'Command' => [
                'Name' => 'glueetl',
                'ScriptLocation' => $scriptLocation,
                'PythonVersion' => $pythonVersion,
            ],
            'GlueVersion' => $glueVersion,
        ]);
    }

    public function startJobRun($jobName, $databaseName, $tables,
$outputBucketUrl): Result
    {
        return $this->glueClient->startJobRun([
            'JobName' => $jobName,
            'Arguments' => [
                'input_database' => $databaseName,
                'input_table' => $tables['TableList'][0]['Name'],
            ],
        ]);
    }

```

```

        'output_bucket_url' => $outputBucketUrl,
        '--input_database' => $databaseName,
        '--input_table' => $tables['TableList'][0]['Name'],
        '--output_bucket_url' => $outputBucketUrl,
    ],
    ));
}

public function listJobs($maxResults = null, $nextToken = null, $tags = []):
Result
{
    $arguments = [];
    if ($maxResults) {
        $arguments['MaxResults'] = $maxResults;
    }
    if ($nextToken) {
        $arguments['NextToken'] = $nextToken;
    }
    if (!empty($tags)) {
        $arguments['Tags'] = $tags;
    }
    return $this->glueClient->listJobs($arguments);
}

public function getJobRuns($jobName, $maxResults = 0, $nextToken = ''):
Result
{
    $arguments = ['JobName' => $jobName];
    if ($maxResults) {
        $arguments['MaxResults'] = $maxResults;
    }
    if ($nextToken) {
        $arguments['NextToken'] = $nextToken;
    }
    return $this->glueClient->getJobRuns($arguments);
}

public function getJobRun($jobName, $runId, $predecessorsIncluded = false):
Result
{
    return $this->glueClient->getJobRun([
        'JobName' => $jobName,
        'RunId' => $runId,
        'PredecessorsIncluded' => $predecessorsIncluded,
    ]);
}

```

```
    });  
}  
  
public function deleteJob($jobName)  
{  
    return $this->glueClient->deleteJob([  
        'JobName' => $jobName,  
    ]);  
}  
  
public function deleteTable($tableName, $databaseName)  
{  
    return $this->glueClient->deleteTable([  
        'DatabaseName' => $databaseName,  
        'Name' => $tableName,  
    ]);  
}  
  
public function deleteDatabase($databaseName)  
{  
    return $this->glueClient->deleteDatabase([  
        'Name' => $databaseName,  
    ]);  
}  
  
public function deleteCrawler($crawlerName)  
{  
    return $this->glueClient->deleteCrawler([  
        'Name' => $crawlerName,  
    ]);  
}  
}
```

- Pour plus d'informations sur l'API, consultez les rubriques suivantes dans la référence de l'API AWS SDK pour PHP .
 - [CreateCrawler](#)
 - [CreateJob](#)
 - [DeleteCrawler](#)
 - [DeleteDatabase](#)
 - [DeleteJob](#)

- [DeleteTable](#)
- [GetCrawler](#)
- [GetDatabase](#)
- [GetDatabases](#)
- [GetJob](#)
- [GetJobRun](#)
- [GetJobRuns](#)
- [GetTables](#)
- [ListJobs](#)
- [StartCrawler](#)
- [StartJobRun](#)

Python

SDK pour Python (Boto3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

Créez une classe qui englobe les AWS Glue fonctions utilisées dans le scénario.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def get_crawler(self, name):
        """
        Gets information about a crawler.
```

```

:param name: The name of the crawler to look up.
:return: Data about the crawler.
"""
crawler = None
try:
    response = self.glue_client.get_crawler(Name=name)
    crawler = response["Crawler"]
except ClientError as err:
    if err.response["Error"]["Code"] == "EntityNotFoundException":
        logger.info("Crawler %s doesn't exist.", name)
    else:
        logger.error(
            "Couldn't get crawler %s. Here's why: %s: %s",
            name,
            err.response["Error"]["Code"],
            err.response["Error"]["Message"],
        )
        raise
return crawler

def create_crawler(self, name, role_arn, db_name, db_prefix, s3_target):
    """
    Creates a crawler that can crawl the specified target and populate a
    database in your AWS Glue Data Catalog with metadata that describes the
data
    in the target.

    :param name: The name of the crawler.
    :param role_arn: The Amazon Resource Name (ARN) of an AWS Identity and
Access
Management (IAM) role that grants permission to let AWS
Glue
access the resources it needs.
    :param db_name: The name to give the database that is created by the
crawler.
    :param db_prefix: The prefix to give any database tables that are created
by
the crawler.
    :param s3_target: The URL to an S3 bucket that contains data that is
the target of the crawler.
    """
    try:

```

```

        self.glue_client.create_crawler(
            Name=name,
            Role=role_arn,
            DatabaseName=db_name,
            TablePrefix=db_prefix,
            Targets={"S3Targets": [{"Path": s3_target}]},
        )
    except ClientError as err:
        logger.error(
            "Couldn't create crawler. Here's why: %s: %s",
            err.response["Error"]["Code"],
            err.response["Error"]["Message"],
        )
        raise

def start_crawler(self, name):
    """
    Starts a crawler. The crawler crawls its configured target and creates
    metadata that describes the data it finds in the target data source.

    :param name: The name of the crawler to start.
    """
    try:
        self.glue_client.start_crawler(Name=name)
    except ClientError as err:
        logger.error(
            "Couldn't start crawler %s. Here's why: %s: %s",
            name,
            err.response["Error"]["Code"],
            err.response["Error"]["Message"],
        )
        raise

def get_database(self, name):
    """
    Gets information about a database in your Data Catalog.

    :param name: The name of the database to look up.
    :return: Information about the database.
    """
    try:
        response = self.glue_client.get_database(Name=name)

```



```

except ClientError as err:
    logger.error(
        "Couldn't get database %s. Here's why: %s: %s",
        name,
        err.response["Error"]["Code"],
        err.response["Error"]["Message"],
    )
    raise
else:
    return response["Database"]

def get_tables(self, db_name):
    """
    Gets a list of tables in a Data Catalog database.

    :param db_name: The name of the database to query.
    :return: The list of tables in the database.
    """
    try:
        response = self.glue_client.get_tables(DatabaseName=db_name)
    except ClientError as err:
        logger.error(
            "Couldn't get tables %s. Here's why: %s: %s",
            db_name,
            err.response["Error"]["Code"],
            err.response["Error"]["Message"],
        )
        raise
    else:
        return response["TableList"]

def create_job(self, name, description, role_arn, script_location):
    """
    Creates a job definition for an extract, transform, and load (ETL) job
    that can
    be run by AWS Glue.

    :param name: The name of the job definition.
    :param description: The description of the job definition.
    :param role_arn: The ARN of an IAM role that grants AWS Glue the
    permissions
    it requires to run the job.

```

```

        :param script_location: The Amazon S3 URL of a Python ETL script that is
run as
                                part of the job. The script defines how the data
is
                                transformed.

        """
        try:
            self.glue_client.create_job(
                Name=name,
                Description=description,
                Role=role_arn,
                Command={
                    "Name": "glueetl",
                    "ScriptLocation": script_location,
                    "PythonVersion": "3",
                },
                GlueVersion="3.0",
            )
        except ClientError as err:
            logger.error(
                "Couldn't create job %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise

    def start_job_run(self, name, input_database, input_table,
output_bucket_name):
        """
        Starts a job run. A job run extracts data from the source, transforms it,
and loads it to the output bucket.

        :param name: The name of the job definition.
        :param input_database: The name of the metadata database that contains
tables
                                that describe the source data. This is typically
created
                                by a crawler.
        :param input_table: The name of the table in the metadata database that
describes the source data.
        :param output_bucket_name: The S3 bucket where the output is written.
        :return: The ID of the job run.

```

```

        """
        try:
            # The custom Arguments that are passed to this function are used by
            # Python ETL script to determine the location of input and output
            data.

            response = self.glue_client.start_job_run(
                JobName=name,
                Arguments={
                    "--input_database": input_database,
                    "--input_table": input_table,
                    "--output_bucket_url": f"s3://{output_bucket_name}/",
                },
            )
        except ClientError as err:
            logger.error(
                "Couldn't start job run %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobRunId"]

    def list_jobs(self):
        """
        Lists the names of job definitions in your account.

        :return: The list of job definition names.
        """
        try:
            response = self.glue_client.list_jobs()
        except ClientError as err:
            logger.error(
                "Couldn't list jobs. Here's why: %s: %s",
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobNames"]

```

```
def get_job_runs(self, job_name):
    """
    Gets information about runs that have been performed for a specific job
    definition.

    :param job_name: The name of the job definition to look up.
    :return: The list of job runs.
    """
    try:
        response = self.glue_client.get_job_runs(JobName=job_name)
    except ClientError as err:
        logger.error(
            "Couldn't get job runs for %s. Here's why: %s: %s",
            job_name,
            err.response["Error"]["Code"],
            err.response["Error"]["Message"],
        )
        raise
    else:
        return response["JobRuns"]


def get_job_run(self, name, run_id):
    """
    Gets information about a single job run.

    :param name: The name of the job definition for the run.
    :param run_id: The ID of the run.
    :return: Information about the run.
    """
    try:
        response = self.glue_client.get_job_run(JobName=name, RunId=run_id)
    except ClientError as err:
        logger.error(
            "Couldn't get job run %s/%s. Here's why: %s: %s",
            name,
            run_id,
            err.response["Error"]["Code"],
            err.response["Error"]["Message"],
        )
        raise
    else:
        return response["JobRun"]
```

```
def delete_job(self, job_name):
    """
    Deletes a job definition. This also deletes data about all runs that are
    associated with this job definition.

    :param job_name: The name of the job definition to delete.
    """
    try:
        self.glue_client.delete_job(JobName=job_name)
    except ClientError as err:
        logger.error(
            "Couldn't delete job %s. Here's why: %s: %s",
            job_name,
            err.response["Error"]["Code"],
            err.response["Error"]["Message"],
        )
        raise

def delete_table(self, db_name, table_name):
    """
    Deletes a table from a metadata database.

    :param db_name: The name of the database that contains the table.
    :param table_name: The name of the table to delete.
    """
    try:
        self.glue_client.delete_table(DatabaseName=db_name, Name=table_name)
    except ClientError as err:
        logger.error(
            "Couldn't delete table %s. Here's why: %s: %s",
            table_name,
            err.response["Error"]["Code"],
            err.response["Error"]["Message"],
        )
        raise

def delete_database(self, name):
    """
    Deletes a metadata database from your Data Catalog.
```

```

        :param name: The name of the database to delete.
        """
        try:
            self.glue_client.delete_database(Name=name)
        except ClientError as err:
            logger.error(
                "Couldn't delete database %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise

    def delete_crawler(self, name):
        """
        Deletes a crawler.

        :param name: The name of the crawler to delete.
        """
        try:
            self.glue_client.delete_crawler(Name=name)
        except ClientError as err:
            logger.error(
                "Couldn't delete crawler %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise

```

Créez une classe qui exécute le scénario.

```

class GlueCrawlerJobScenario:
    """
    Encapsulates a scenario that shows how to create an AWS Glue crawler and job
    and use
    them to transform data from CSV to JSON format.
    """

```

```

def __init__(self, glue_client, glue_service_role, glue_bucket):
    """
    :param glue_client: A Boto3 AWS Glue client.
    :param glue_service_role: An AWS Identity and Access Management (IAM)
role
                                that AWS Glue can assume to gain access to the
                                resources it requires.
    :param glue_bucket: An S3 bucket that can hold a job script and output
data
                                from AWS Glue job runs.
    """
    self.glue_client = glue_client
    self.glue_service_role = glue_service_role
    self.glue_bucket = glue_bucket

    @staticmethod
    def wait(seconds, tick=12):
        """
        Waits for a specified number of seconds, while also displaying an
animated
        spinner.

        :param seconds: The number of seconds to wait.
        :param tick: The number of frames per second used to animate the spinner.
        """
        progress = "|/-\\"
        waited = 0
        while waited < seconds:
            for frame in range(tick):
                sys.stdout.write(f"\r{progress[frame % len(progress)]}")
                sys.stdout.flush()
                time.sleep(1 / tick)
            waited += 1

    def upload_job_script(self, job_script):
        """
        Uploads a Python ETL script to an S3 bucket. The script is used by the
AWS Glue
        job to transform data.

        :param job_script: The relative path to the job script.
        """
        try:

```

```

        self.glue_bucket.upload_file(Filename=job_script, Key=job_script)
        print(f"Uploaded job script '{job_script}' to the example bucket.")
    except S3UploadFailedError as err:
        logger.error("Couldn't upload job script. Here's why: %s", err)
        raise

    def run(self, crawler_name, db_name, db_prefix, data_source, job_script,
job_name):
        """
        Runs the scenario. This is an interactive experience that runs at a
command
prompt and asks you for input throughout.

        :param crawler_name: The name of the crawler used in the scenario. If the
            crawler does not exist, it is created.
        :param db_name: The name to give the metadata database created by the
crawler.
        :param db_prefix: The prefix to give tables added to the database by the
            crawler.
        :param data_source: The location of the data source that is targeted by
the
            crawler and extracted during job runs.
        :param job_script: The job script that is used to transform data during
job
            runs.
        :param job_name: The name to give the job definition that is created
during the
            scenario.
        """
        wrapper = GlueWrapper(self.glue_client)
        print(f"Checking for crawler {crawler_name}.")
        crawler = wrapper.get_crawler(crawler_name)
        if crawler is None:
            print(f"Creating crawler {crawler_name}.")
            wrapper.create_crawler(
                crawler_name,
                self.glue_service_role.arn,
                db_name,
                db_prefix,
                data_source,
            )
            print(f"Created crawler {crawler_name}.")
            crawler = wrapper.get_crawler(crawler_name)
        pprint(crawler)

```



```

        print("-" * 88)

        print(
            f"When you run the crawler, it crawls data stored in {data_source}
and "
            f"creates a metadata database in the AWS Glue Data Catalog that
describes "
            f"the data in the data source."
        )
        print("In this example, the source data is in CSV format.")
        ready = False
        while not ready:
            ready = Question.ask_question(
                "Ready to start the crawler? (y/n) ", Question.is_yesno
            )
        wrapper.start_crawler(crawler_name)
        print("Let's wait for the crawler to run. This typically takes a few
minutes.")
        crawler_state = None
        while crawler_state != "READY":
            self.wait(10)
            crawler = wrapper.get_crawler(crawler_name)
            crawler_state = crawler["State"]
            print(f"Crawler is {crawler['State']}")
        print("-" * 88)

        database = wrapper.get_database(db_name)
        print(f"The crawler created database {db_name}:")
        pprint(database)
        print(f"The database contains these tables:")
        tables = wrapper.get_tables(db_name)
        for index, table in enumerate(tables):
            print(f"\t{index + 1}. {table['Name']}")
        table_index = Question.ask_question(
            f"Enter the number of a table to see more detail: ",
            Question.is_int,
            Question.in_range(1, len(tables)),
        )
        pprint(tables[table_index - 1])
        print("-" * 88)

        print(f"Creating job definition {job_name}.")
        wrapper.create_job(
            job_name,

```

```

        "Getting started example job.",
        self.glue_service_role.arn,
        f"s3://{self.glue_bucket.name}/{job_script}",
    )
    print("Created job definition.")
    print(
        f"When you run the job, it extracts data from {data_source},
transforms it "
        f"by using the {job_script} script, and loads the output into "
        f"S3 bucket {self.glue_bucket.name}."
    )
    print(
        "In this example, the data is transformed from CSV to JSON, and only
a few "
        "fields are included in the output."
    )
    job_run_status = None
    if Question.ask_question(f"Ready to run? (y/n) ", Question.is_yesno):
        job_run_id = wrapper.start_job_run(
            job_name, db_name, tables[0]["Name"], self.glue_bucket.name
        )
        print(f"Job {job_name} started. Let's wait for it to run.")
        while job_run_status not in ["SUCCEEDED", "STOPPED", "FAILED",
"TIMEOUT"]:
            self.wait(10)
            job_run = wrapper.get_job_run(job_name, job_run_id)
            job_run_status = job_run["JobRunState"]
            print(f"Job {job_name}/{job_run_id} is {job_run_status}.")
        print("-" * 88)

        if job_run_status == "SUCCEEDED":
            print(
                f"Data from your job run is stored in your S3 bucket
'{self.glue_bucket.name}':"
            )
            try:
                keys = [
                    obj.key for obj in
self.glue_bucket.objects.filter(Prefix="run-")
                ]
                for index, key in enumerate(keys):
                    print(f"\t{index + 1}: {key}")
                lines = 4
                key_index = Question.ask_question(

```

```

        f"Enter the number of a block to download it and see the
first {lines} "
        f"lines of JSON output in the block: ",
        Question.is_int,
        Question.in_range(1, len(keys)),
    )
    job_data = io.BytesIO()
    self.glue_bucket.download_fileobj(keys[key_index - 1], job_data)
    job_data.seek(0)
    for _ in range(lines):
        print(job_data.readline().decode("utf-8"))
except ClientError as err:
    logger.error(
        "Couldn't get job run data. Here's why: %s: %s",
        err.response["Error"]["Code"],
        err.response["Error"]["Message"],
    )
    raise
print("-" * 88)

job_names = wrapper.list_jobs()
if job_names:
    print(f"Your account has {len(job_names)} jobs defined:")
    for index, job_name in enumerate(job_names):
        print(f"\t{index + 1}. {job_name}")
    job_index = Question.ask_question(
        f"Enter a number between 1 and {len(job_names)} to see the list
of runs for "
        f"a job: ",
        Question.is_int,
        Question.in_range(1, len(job_names)),
    )
    job_runs = wrapper.get_job_runs(job_names[job_index - 1])
    if job_runs:
        print(f"Found {len(job_runs)} runs for job {job_names[job_index -
1]]}:")

        for index, job_run in enumerate(job_runs):
            print(
                f"\t{index + 1}. {job_run['JobRunState']} on "
                f"{job_run['CompletedOn']:%Y-%m-%d %H:%M:%S}"
            )
        run_index = Question.ask_question(
            f"Enter a number between 1 and {len(job_runs)} to see details
for a run: ",

```

```

        Question.is_int,
        Question.in_range(1, len(job_runs)),
    )
    pprint(job_runs[run_index - 1])
else:
    print(f"No runs found for job {job_names[job_index - 1]}")
else:
    print("Your account doesn't have any jobs defined.")
print("-" * 88)

print(
    f"Let's clean up. During this example we created job definition
    '{job_name}'."
)
if Question.ask_question(
    "Do you want to delete the definition and all runs? (y/n) ",
    Question.is_yesno,
):
    wrapper.delete_job(job_name)
    print(f"Job definition '{job_name}' deleted.")
tables = wrapper.get_tables(db_name)
print(f"We also created database '{db_name}' that contains these
tables:")
for table in tables:
    print(f"\t{table['Name']}")
if Question.ask_question(
    "Do you want to delete the tables and the database? (y/n) ",
    Question.is_yesno,
):
    for table in tables:
        wrapper.delete_table(db_name, table["Name"])
        print(f"Deleted table {table['Name']}")
    wrapper.delete_database(db_name)
    print(f"Deleted database {db_name}.")
print(f"We also created crawler '{crawler_name}'.")
if Question.ask_question(
    "Do you want to delete the crawler? (y/n) ", Question.is_yesno
):
    wrapper.delete_crawler(crawler_name)
    print(f"Deleted crawler {crawler_name}.")
print("-" * 88)

def parse_args(args):

```

```

"""
Parse command line arguments.

:param args: The command line arguments.
:return: The parsed arguments.
"""
parser = argparse.ArgumentParser(
    description="Runs the AWS Glue getting started with crawlers and jobs
scenario. "
    "Before you run this scenario, set up scaffold resources by running "
    "'python scaffold.py deploy'."
)
parser.add_argument(
    "role_name",
    help="The name of an IAM role that AWS Glue can assume. This role must
grant access "
    "to Amazon S3 and to the permissions granted by the AWSGlueServiceRole "
    "managed policy.",
)
parser.add_argument(
    "bucket_name",
    help="The name of an S3 bucket that AWS Glue can access to get the job
script and "
    "put job results.",
)
parser.add_argument(
    "--job_script",
    default="flight_etl_job_script.py",
    help="The name of the job script file that is used in the scenario.",
)
return parser.parse_args(args)

def main():
    args = parse_args(sys.argv[1:])
    try:
        print("-" * 88)
        print(
            "Welcome to the AWS Glue getting started with crawlers and jobs
scenario."
        )
        print("-" * 88)
        scenario = GlueCrawlerJobScenario(
            boto3.client("glue"),

```

```

        boto3.resource("iam").Role(args.role_name),
        boto3.resource("s3").Bucket(args.bucket_name),
    )
    scenario.upload_job_script(args.job_script)
    scenario.run(
        "doc-example-crawler",
        "doc-example-database",
        "doc-example-",
        "s3://crawler-public-us-east-1/flight/2016/csv",
        args.job_script,
        "doc-example-job",
    )
    print("-" * 88)
    print(
        "To destroy scaffold resources, including the IAM role and S3 bucket
"
        "used in this scenario, run 'python scaffold.py destroy'."
    )
    print("\nThanks for watching!")
    print("-" * 88)
except Exception:
    logging.exception("Something went wrong with the example.")

```

Créez un script ETL utilisé AWS Glue pour extraire, transformer et charger des données lors de l'exécution des tâches.

```

import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

"""
These custom arguments must be passed as Arguments to the StartJobRun request.
    --input_database      The name of a metadata database that is contained in
your
                        AWS Glue Data Catalog and that contains tables that
describe
                        the data to be processed.

```

```

    --input_table          The name of a table in the database that describes the
data to
                           be processed.
    --output_bucket_url An S3 bucket that receives the transformed output data.
"""
args = getResolvedOptions(
    sys.argv, ["JOB_NAME", "input_database", "input_table", "output_bucket_url"]
)
sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args["JOB_NAME"], args)

# Script generated for node S3 Flight Data.
S3FlightData_node1 = glueContext.create_dynamic_frame.from_catalog(
    database=args["input_database"],
    table_name=args["input_table"],
    transformation_ctx="S3FlightData_node1",
)

# This mapping performs two main functions:
# 1. It simplifies the output by removing most of the fields from the data.
# 2. It renames some fields. For example, `fl_date` is renamed to `flight_date`.
ApplyMapping_node2 = ApplyMapping.apply(
    frame=S3FlightData_node1,
    mappings=[
        ("year", "long", "year", "long"),
        ("month", "long", "month", "tinyint"),
        ("day_of_month", "long", "day", "tinyint"),
        ("fl_date", "string", "flight_date", "string"),
        ("carrier", "string", "carrier", "string"),
        ("fl_num", "long", "flight_num", "long"),
        ("origin_city_name", "string", "origin_city_name", "string"),
        ("origin_state_abr", "string", "origin_state_abr", "string"),
        ("dest_city_name", "string", "dest_city_name", "string"),
        ("dest_state_abr", "string", "dest_state_abr", "string"),
        ("dep_time", "long", "departure_time", "long"),
        ("wheels_off", "long", "wheels_off", "long"),
        ("wheels_on", "long", "wheels_on", "long"),
        ("arr_time", "long", "arrival_time", "long"),
        ("mon", "string", "mon", "string"),
    ],
    transformation_ctx="ApplyMapping_node2",

```

```
)

# Script generated for node Revised Flight Data.
RevisedFlightData_node3 = glueContext.write_dynamic_frame.from_options(
    frame=ApplyMapping_node2,
    connection_type="s3",
    format="json",
    connection_options={"path": args["output_bucket_url"], "partitionKeys": []},
    transformation_ctx="RevisedFlightData_node3",
)

job.commit()
```

- Pour plus d'informations sur l'API, consultez les rubriques suivantes dans AWS SDK for Python (Boto3) API Reference.
 - [CreateCrawler](#)
 - [CreateJob](#)
 - [DeleteCrawler](#)
 - [DeleteDatabase](#)
 - [DeleteJob](#)
 - [DeleteTable](#)
 - [GetCrawler](#)
 - [GetDatabase](#)
 - [GetDatabases](#)
 - [GetJob](#)
 - [GetJobRun](#)
 - [GetJobRuns](#)
 - [GetTables](#)
 - [ListJobs](#)
 - [StartCrawler](#)
 - [StartJobRun](#)

Ruby

Kit SDK pour Ruby

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

Créez une classe qui englobe les AWS Glue fonctions utilisées dans le scénario.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Retrieves information about a specific crawler.
  #
  # @param name [String] The name of the crawler to retrieve information about.
  # @return [Aws::Glue::Types::Crawler, nil] The crawler object if found, or nil
  # if not found.
  def get_crawler(name)
    @glue_client.get_crawler(name: name)
  rescue Aws::Glue::Errors::EntityNotFoundException
    @logger.info("Crawler #{name} doesn't exist.")
    false
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get crawler #{name}: \n#{e.message}")
    raise
  end

  # Creates a new crawler with the specified configuration.
  #
  # @param name [String] The name of the crawler.
```

```

# @param role_arn [String] The ARN of the IAM role to be used by the crawler.
# @param db_name [String] The name of the database where the crawler stores its
metadata.
# @param db_prefix [String] The prefix to be added to the names of tables that
the crawler creates.
# @param s3_target [String] The S3 path that the crawler will crawl.
# @return [void]
def create_crawler(name, role_arn, db_name, _db_prefix, s3_target)
  @glue_client.create_crawler(
    name: name,
    role: role_arn,
    database_name: db_name,
    targets: {
      s3_targets: [
        {
          path: s3_target
        }
      ]
    }
  )
rescue Aws::Glue::Errors::GlueException => e
  @logger.error("Glue could not create crawler: \n#{e.message}")
  raise
end

# Starts a crawler with the specified name.
#
# @param name [String] The name of the crawler to start.
# @return [void]
def start_crawler(name)
  @glue_client.start_crawler(name: name)
rescue Aws::Glue::Errors::ServiceError => e
  @logger.error("Glue could not start crawler #{name}: \n#{e.message}")
  raise
end

# Deletes a crawler with the specified name.
#
# @param name [String] The name of the crawler to delete.
# @return [void]
def delete_crawler(name)
  @glue_client.delete_crawler(name: name)
rescue Aws::Glue::Errors::ServiceError => e
  @logger.error("Glue could not delete crawler #{name}: \n#{e.message}")

```

```
    raise
  end

  # Retrieves information about a specific database.
  #
  # @param name [String] The name of the database to retrieve information about.
  # @return [Aws::Glue::Types::Database, nil] The database object if found, or
  nil if not found.
  def get_database(name)
    response = @glue_client.get_database(name: name)
    response.database
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get database #{name}: \n#{e.message}")
    raise
  end

  # Retrieves a list of tables in the specified database.
  #
  # @param db_name [String] The name of the database to retrieve tables from.
  # @return [Array<Aws::Glue::Types::Table>]
  def get_tables(db_name)
    response = @glue_client.get_tables(database_name: db_name)
    response.table_list
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get tables #{db_name}: \n#{e.message}")
    raise
  end

  # Creates a new job with the specified configuration.
  #
  # @param name [String] The name of the job.
  # @param description [String] The description of the job.
  # @param role_arn [String] The ARN of the IAM role to be used by the job.
  # @param script_location [String] The location of the ETL script for the job.
  # @return [void]
  def create_job(name, description, role_arn, script_location)
    @glue_client.create_job(
      name: name,
      description: description,
      role: role_arn,
      command: {
        name: 'glueetl',
        script_location: script_location,
        python_version: '3'
      }
    )
  end
end
```

```

    },
    glue_version: '3.0'
  )
rescue Aws::Glue::Errors::GlueException => e
  @logger.error("Glue could not create job #{name}: \n#{e.message}")
  raise
end

# Starts a job run for the specified job.
#
# @param name [String] The name of the job to start the run for.
# @param input_database [String] The name of the input database for the job.
# @param input_table [String] The name of the input table for the job.
# @param output_bucket_name [String] The name of the output S3 bucket for the
job.
# @return [String] The ID of the started job run.
def start_job_run(name, input_database, input_table, output_bucket_name)
  response = @glue_client.start_job_run(
    job_name: name,
    arguments: {
      '--input_database': input_database,
      '--input_table': input_table,
      '--output_bucket_url': "s3://#{output_bucket_name}/"
    }
  )
  response.job_run_id
rescue Aws::Glue::Errors::GlueException => e
  @logger.error("Glue could not start job run #{name}: \n#{e.message}")
  raise
end

# Retrieves a list of jobs in AWS Glue.
#
# @return [Aws::Glue::Types::ListJobsResponse]
def list_jobs
  @glue_client.list_jobs
rescue Aws::Glue::Errors::GlueException => e
  @logger.error("Glue could not list jobs: \n#{e.message}")
  raise
end

# Retrieves a list of job runs for the specified job.
#
# @param job_name [String] The name of the job to retrieve job runs for.

```

```
# @return [Array<Aws::Glue::Types::JobRun>]
def get_job_runs(job_name)
  response = @glue_client.get_job_runs(job_name: job_name)
  response.job_runs
rescue Aws::Glue::Errors::GlueException => e
  @logger.error("Glue could not get job runs: \n#{e.message}")
end

# Retrieves data for a specific job run.
#
# @param job_name [String] The name of the job run to retrieve data for.
# @return [Glue::Types::GetJobRunResponse]
def get_job_run(job_name, run_id)
  @glue_client.get_job_run(job_name: job_name, run_id: run_id)
rescue Aws::Glue::Errors::GlueException => e
  @logger.error("Glue could not get job runs: \n#{e.message}")
end

# Deletes a job with the specified name.
#
# @param job_name [String] The name of the job to delete.
# @return [void]
def delete_job(job_name)
  @glue_client.delete_job(job_name: job_name)
rescue Aws::Glue::Errors::ServiceError => e
  @logger.error("Glue could not delete job: \n#{e.message}")
end

# Deletes a table with the specified name.
#
# @param database_name [String] The name of the catalog database in which the
table resides.
# @param table_name [String] The name of the table to be deleted.
# @return [void]
def delete_table(database_name, table_name)
  @glue_client.delete_table(database_name: database_name, name: table_name)
rescue Aws::Glue::Errors::ServiceError => e
  @logger.error("Glue could not delete job: \n#{e.message}")
end

# Removes a specified database from a Data Catalog.
#
# @param database_name [String] The name of the database to delete.
# @return [void]
```

```

def delete_database(database_name)
  @glue_client.delete_database(name: database_name)
rescue Aws::Glue::Errors::ServiceError => e
  @logger.error("Glue could not delete database: \n#{e.message}")
end

# Uploads a job script file to an S3 bucket.
#
# @param file_path [String] The local path of the job script file.
# @param bucket_resource [Aws::S3::Bucket] The S3 bucket resource to upload the
file to.
# @return [void]
def upload_job_script(file_path, bucket_resource)
  File.open(file_path) do |file|
    bucket_resource.client.put_object({
      body: file,
      bucket: bucket_resource.name,
      key: file_path
    })
  end
rescue Aws::S3::Errors::S3UploadFailedError => e
  @logger.error("S3 could not upload job script: \n#{e.message}")
  raise
end
end

```

Créez une classe qui exécute le scénario.

```

class GlueCrawlerJobScenario
  def initialize(glue_client, glue_service_role, glue_bucket, logger)
    @glue_client = glue_client
    @glue_service_role = glue_service_role
    @glue_bucket = glue_bucket
    @logger = logger
  end

  def run(crawler_name, db_name, db_prefix, data_source, job_script, job_name)
    wrapper = GlueWrapper.new(@glue_client, @logger)
    setup_crawler(wrapper, crawler_name, db_name, db_prefix, data_source)
    query_database(wrapper, crawler_name, db_name)
    create_and_run_job(wrapper, job_script, job_name, db_name)
  end
end

```

```

private

def setup_crawler(wrapper, crawler_name, db_name, db_prefix, data_source)
  new_step(1, 'Create a crawler')
  crawler = wrapper.get_crawler(crawler_name)
  unless crawler
    puts "Creating crawler #{crawler_name}."
    wrapper.create_crawler(crawler_name, @glue_service_role.arn, db_name,
db_prefix, data_source)
    puts "Successfully created #{crawler_name}."
  end
  wrapper.start_crawler(crawler_name)
  monitor_crawler(wrapper, crawler_name)
end

def monitor_crawler(wrapper, crawler_name)
  new_step(2, 'Monitor Crawler')
  crawler_state = nil
  until crawler_state == 'READY'
    custom_wait(15)
    crawler = wrapper.get_crawler(crawler_name)
    crawler_state = crawler[0]['state']
    print "Crawler status: #{crawler_state}".yellow
  end
end

def query_database(wrapper, _crawler_name, db_name)
  new_step(3, 'Query the database.')
  wrapper.get_database(db_name)
  puts "The crawler created database #{db_name}:"
  puts "Database contains tables: #{wrapper.get_tables(db_name).map { |t|
t['name'] }}"
end

def create_and_run_job(wrapper, job_script, job_name, db_name)
  new_step(4, 'Create and run job.')
  wrapper.upload_job_script(job_script, @glue_bucket)
  wrapper.create_job(job_name, 'ETL Job', @glue_service_role.arn, "s3://
#{@glue_bucket.name}/#{job_script}")
  run_job(wrapper, job_name, db_name)
end

def run_job(wrapper, job_name, db_name)

```

```

    new_step(5, 'Run the job.')
    wrapper.start_job_run(job_name, db_name, wrapper.get_tables(db_name)[0]
['name'], @glue_bucket.name)
    job_run_status = nil
    until %w[SUCCEEDED FAILED STOPPED].include?(job_run_status)
        custom_wait(10)
        job_run = wrapper.get_job_runs(job_name)
        job_run_status = job_run[0]['job_run_state']
        print "Job #{job_name} status: #{job_run_status}".yellow
    end
end
end

def main
  banner('../../helpers/banner.txt')
  puts 'Starting AWS Glue demo...'

  # Load resource names from YAML.
  resource_names = YAML.load_file('resource_names.yaml')

  # Setup services and resources.
  iam_role = Aws::IAM::Resource.new(region: 'us-
east-1').role(resource_names['glue_service_role'])
  s3_bucket = Aws::S3::Resource.new(region: 'us-
east-1').bucket(resource_names['glue_bucket'])

  # Instantiate scenario and run.
  scenario = GlueCrawlerJobScenario.new(Aws::Glue::Client.new(region: 'us-
east-1'), iam_role, s3_bucket, @logger)
  random_suffix = rand(10**4)
  scenario.run("crawler-#{random_suffix}", "db-#{random_suffix}", "prefix-
#{random_suffix}-", 's3://data_source',
              'job_script.py', "job-#{random_suffix}")

  puts 'Demo complete.'
end

```

Créez un script ETL utilisé AWS Glue pour extraire, transformer et charger des données lors de l'exécution des tâches.

```

import sys
from awsglue.transforms import *

```



```

from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

"""
These custom arguments must be passed as Arguments to the StartJobRun request.
    --input_database      The name of a metadata database that is contained in
your                               AWS Glue Data Catalog and that contains tables that
describe                               the data to be processed.
    --input_table        The name of a table in the database that describes the
data to                               be processed.
    --output_bucket_url  An S3 bucket that receives the transformed output data.
"""
args = getResolvedOptions(
    sys.argv, ["JOB_NAME", "input_database", "input_table", "output_bucket_url"]
)
sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args["JOB_NAME"], args)

# Script generated for node S3 Flight Data.
S3FlightData_node1 = glueContext.create_dynamic_frame.from_catalog(
    database=args["input_database"],
    table_name=args["input_table"],
    transformation_ctx="S3FlightData_node1",
)

# This mapping performs two main functions:
# 1. It simplifies the output by removing most of the fields from the data.
# 2. It renames some fields. For example, `fl_date` is renamed to `flight_date`.
ApplyMapping_node2 = ApplyMapping.apply(
    frame=S3FlightData_node1,
    mappings=[
        ("year", "long", "year", "long"),
        ("month", "long", "month", "tinyint"),
        ("day_of_month", "long", "day", "tinyint"),
        ("fl_date", "string", "flight_date", "string"),
        ("carrier", "string", "carrier", "string"),
    ],
)

```

```

        ("fl_num", "long", "flight_num", "long"),
        ("origin_city_name", "string", "origin_city_name", "string"),
        ("origin_state_abr", "string", "origin_state_abr", "string"),
        ("dest_city_name", "string", "dest_city_name", "string"),
        ("dest_state_abr", "string", "dest_state_abr", "string"),
        ("dep_time", "long", "departure_time", "long"),
        ("wheels_off", "long", "wheels_off", "long"),
        ("wheels_on", "long", "wheels_on", "long"),
        ("arr_time", "long", "arrival_time", "long"),
        ("mon", "string", "mon", "string"),
    ],
    transformation_ctx="ApplyMapping_node2",
)

# Script generated for node Revised Flight Data.
RevisedFlightData_node3 = glueContext.write_dynamic_frame.from_options(
    frame=ApplyMapping_node2,
    connection_type="s3",
    format="json",
    connection_options={"path": args["output_bucket_url"], "partitionKeys": []},
    transformation_ctx="RevisedFlightData_node3",
)

job.commit()

```

- Pour plus d'informations sur l'API consultez les rubriques suivantes dans la référence de l'API AWS SDK pour Ruby .
 - [CreateCrawler](#)
 - [CreateJob](#)
 - [DeleteCrawler](#)
 - [DeleteDatabase](#)
 - [DeleteJob](#)
 - [DeleteTable](#)
 - [GetCrawler](#)
 - [GetDatabase](#)
 - [GetDatabases](#)
 - [GetJob](#)
 - [GetJobRun](#)

- [GetJobRuns](#)
- [GetTables](#)
- [ListJobs](#)
- [StartCrawler](#)
- [StartJobRun](#)

Rust

SDK pour Rust

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

Créez et exécutez un crawler qui analyse un compartiment Amazon Simple Storage Service (Amazon S3) public et génère une base de données de métadonnées qui décrit les données au format CSV trouvées.

```
let create_crawler = glue
    .create_crawler()
    .name(self.crawler())
    .database_name(self.database())
    .role(self.iam_role.expose_secret())
    .targets(
        CrawlerTargets::builder()
            .s3_targets(S3Target::builder().path(CRAWLER_TARGET).build())
            .build(),
    )
    .send()
    .await;

match create_crawler {
    Err(err) => {
        let glue_err: aws_sdk_glue::Error = err.into();
        match glue_err {
            aws_sdk_glue::Error::AlreadyExistsException(_) => {
                info!("Using existing crawler");
            }
        }
    }
}
```

```

        Ok(())
    }
    _ => Err(GlueMvpError::GlueSdk(glue_err)),
}
}
Ok(_) => Ok(()),
}??;

let start_crawler =
glue.start_crawler().name(self.crawler()).send().await;

match start_crawler {
    Ok(_) => Ok(()),
    Err(err) => {
        let glue_err: aws_sdk_glue::Error = err.into();
        match glue_err {
            aws_sdk_glue::Error::CrawlerRunningException(_) => Ok(()),
            _ => Err(GlueMvpError::GlueSdk(glue_err)),
        }
    }
}??;

```

Répertoriez les informations relatives aux bases de données et aux tables de votre AWS Glue Data Catalog.

```

let database = glue
    .get_database()
    .name(self.database())
    .send()
    .await
    .map_err(GlueMvpError::from_glue_sdk)?
    .to_owned();
let database = database
    .database()
    .ok_or_else(|| GlueMvpError::Unknown("Could not find
database".into()))?;

let tables = glue
    .get_tables()
    .database_name(self.database())
    .send()
    .await

```

```

        .map_err(GlueMvpError::from_glue_sdk)?;

let tables = tables.table_list();

```

Créez et exécutez une tâche qui extrait les données CSV du compartiment Amazon S3 source, les transforme en supprimant et en renommant des champs, et charge la sortie au format JSON dans un autre compartiment Amazon S3.

```

let create_job = glue
    .create_job()
    .name(self.job())
    .role(self.iam_role.expose_secret())
    .command(
        JobCommand::builder()
            .name("glueetl")
            .python_version("3")
            .script_location(format!("s3://{}/job.py", self.bucket()))
            .build(),
    )
    .glue_version("3.0")
    .send()
    .await
    .map_err(GlueMvpError::from_glue_sdk)?;

let job_name = create_job.name().ok_or_else(|| {
    GlueMvpError::Unknown("Did not get job name after creating
job".into())
})?;

let job_run_output = glue
    .start_job_run()
    .job_name(self.job())
    .arguments("--input_database", self.database())
    .arguments(
        "--input_table",
        self.tables
            .first()
            .ok_or_else(|| GlueMvpError::Unknown("Missing crawler
table".into()))?
            .name(),
    )
    .arguments("--output_bucket_url", self.bucket())

```

```
        .send()
        .await
        .map_err(GlueMvpError::from_glue_sdk)?;

let job = job_run_output
    .job_run_id()
    .ok_or_else(|| GlueMvpError::Unknown("Missing run id from just
started job".into()))?
    .to_string();
```

Supprimez toutes les ressources créées par la démonstration.

```
glue.delete_job()
    .job_name(self.job())
    .send()
    .await
    .map_err(GlueMvpError::from_glue_sdk)?;

for t in &self.tables {
    glue.delete_table()
        .name(t.name())
        .database_name(self.database())
        .send()
        .await
        .map_err(GlueMvpError::from_glue_sdk)?;
}

glue.delete_database()
    .name(self.database())
    .send()
    .await
    .map_err(GlueMvpError::from_glue_sdk)?;

glue.delete_crawler()
    .name(self.crawler())
    .send()
    .await
    .map_err(GlueMvpError::from_glue_sdk)?;
```

- Pour plus d'informations sur l'API, consultez les rubriques suivantes dans AWS SDK for Rust API reference.

- [CreateCrawler](#)
- [CreateJob](#)
- [DeleteCrawler](#)
- [DeleteDatabase](#)
- [DeleteJob](#)
- [DeleteTable](#)
- [GetCrawler](#)
- [GetDatabase](#)
- [GetDatabases](#)
- [GetJob](#)
- [GetJobRun](#)
- [GetJobRuns](#)
- [GetTables](#)
- [ListJobs](#)
- [StartCrawler](#)
- [StartJobRun](#)

Swift

Kit SDK pour Swift

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

Fichier `Package.swift`.

```
// swift-tools-version: 5.9
//
// The swift-tools-version declares the minimum version of Swift required to
// build this package.

import PackageDescription
```

```

let package = Package(
    name: "glue-scenario",
    // Let Xcode know the minimum Apple platforms supported.
    platforms: [
        .macOS(.v13),
        .iOS(.v15)
    ],
    dependencies: [
        // Dependencies declare other packages that this package depends on.
        .package(
            url: "https://github.com/aws-labs/aws-sdk-swift",
            from: "1.0.0"),
        .package(
            url: "https://github.com/apple/swift-argument-parser.git",
            branch: "main"
        )
    ],
    targets: [
        // Targets are the basic building blocks of a package, defining a module
        // or a test suite.
        // Targets can depend on other targets in this package and products
        // from dependencies.
        .executableTarget(
            name: "glue-scenario",
            dependencies: [
                .product(name: "AWSGlue", package: "aws-sdk-swift"),
                .product(name: "AWSS3", package: "aws-sdk-swift"),
                .product(name: "ArgumentParser", package: "swift-argument-
parser")
            ],
            path: "Sources")
    ]
)

```

Le fichier de code Swift, `entry.swift`.

```

// An example that shows how to use the AWS SDK for Swift to demonstrate
// creating and using crawlers and jobs using AWS Glue.
//
// 0. Upload the Python job script to Amazon S3 so it can be used when

```



```
// calling `startJobRun()` later.
// 1. Create a crawler, pass it the IAM role and the URL of the public Amazon
//    S3 bucket that contains the source data:
//    s3://crawler-public-us-east-1/flight/2016/csv.
// 2. Start the crawler. This takes time, so after starting it, use a loop
//    that calls `getCrawler()` until the state is "READY".
// 3. Get the database created by the crawler, and the tables in the
//    database. Display them to the user.
// 4. Create a job. Pass it the IAM role and the URL to a Python ETL script
//    previously uploaded to the user's S3 bucket.
// 5. Start a job run, passing the following custom arguments. These are
//    expected by the ETL script, so must exactly match.
//    * `--input_database: <name of the database created by the crawler>`
//    * `--input_table: <name of the table created by the crawler>`
//    * `--output_bucket_url: <URL to the scaffold bucket created for the
//      user>`
// 6. Loop and get the job run until it returns one of the following states:
//    "SUCCEEDED", "STOPPED", "FAILED", or "TIMEOUT".
// 7. Output data is stored in a group of files in the user's S3 bucket.
//    Either direct the user to their location or download a file and display
//    the results inline.
// 8. List the jobs for the user's account.
// 9. Get job run details for a job run.
// 10. Delete the demo job.
// 11. Delete the database and tables created by the example.
// 12. Delete the crawler created by the example.

import ArgumentParser
import AWSS3
import Foundation
import Smithy

import AWSClientRuntime
import AWSGlue

struct ExampleCommand: ParsableCommand {
    @Option(help: "The AWS IAM role to use for AWS Glue calls.")
    var role: String

    @Option(help: "The Amazon S3 bucket to use for this example.")
    var bucket: String

    @Option(help: "The Amazon S3 URL of the data to crawl.")
    var s3url: String = "s3://crawler-public-us-east-1/flight/2016/csv"
```

```

@Option(help: "The Python script to run as a job with AWS Glue.")
var script: String = "./flight_etl_job_script.py"

@Option(help: "The AWS Region to run AWS API calls in.")
var awsRegion = "us-east-1"

@Option(help: "A prefix string to use when naming tables.")
var tablePrefix = "swift-glue-basics-table"

@Option(
    help: ArgumentHelp("The level of logging for the Swift SDK to perform."),
    completion: .list([
        "critical",
        "debug",
        "error",
        "info",
        "notice",
        "trace",
        "warning"
    ])
)
var logLevel: String = "error"

static var configuration = CommandConfiguration(
    commandName: "glue-scenario",
    abstract: """
Demonstrates various features of AWS Glue.
""",
    discussion: """
An example showing how to use AWS Glue to create, run, and monitor
crawlers and jobs.
""")

/// Generate and return a unique file name that begins with the specified
/// string.
///
/// - Parameters:
///   - prefix: Text to use at the beginning of the returned name.
///
/// - Returns: A string containing a unique filename that begins with the
///   specified `prefix`.
///

```

```

    /// The returned name uses a random number between 1 million and 1 billion to
    /// provide reasonable certainty of uniqueness for the purposes of this
    /// example.
    func tempName(prefix: String) -> String {
        return "\(prefix)-\(Int.random(in: 1000000..<1000000000))"
    }

    /// Upload a file to an Amazon S3 bucket.
    ///
    /// - Parameters:
    ///   - s3Client: The S3 client to use when uploading the file.
    ///   - path: The local path of the source file to upload.
    ///   - toBucket: The name of the S3 bucket into which to upload the file.
    ///   - key: The key (name) to give the file in the S3 bucket.
    ///
    /// - Returns: `true` if the file is uploaded successfully, otherwise
    /// `false`.
    func uploadFile(s3Client: S3Client, path: String, toBucket: String, key:
String) async -> Bool {
        do {
            let fileData: Data = try Data(contentsOf: URL(fileURLWithPath: path))
            let dataStream = ByteStream.data(fileData)
            _ = try await s3Client.putObject(
                input: PutObjectInput(
                    body: dataStream,
                    bucket: toBucket,
                    key: key
                )
            )
        } catch {
            print("*** An unexpected error occurred uploading the script to the
Amazon S3 bucket \"\(bucket)\".")
            return false
        }

        return true
    }

    /// Create a new AWS Glue crawler.
    ///
    /// - Parameters:
    ///   - glueClient: An AWS Glue client to use for the crawler.
    ///   - crawlerName: A name for the new crawler.
    ///   - iamRole: The name of an Amazon IAM role for the crawler to use.

```

```

    /// - s3Path: The path of an Amazon S3 folder to use as a target location.
    /// - cronSchedule: A `cron` schedule indicating when to run the crawler.
    /// - databaseName: The name of an AWS Glue database to operate on.
    ///
    /// - Returns: `true` if the crawler is created successfully, otherwise
    `false`.
    func createCrawler(glueClient: GlueClient, crawlerName: String, iamRole:
String,
                        s3Path: String, cronSchedule: String, databaseName:
String) async -> Bool {
        let s3Target = GlueClientTypes.S3Target(path: s3url)
        let targetList = GlueClientTypes.CrawlerTargets(s3Targets: [s3Target])

        do {
            _ = try await glueClient.createCrawler(
                input: CreateCrawlerInput(
                    databaseName: databaseName,
                    description: "Created by the AWS SDK for Swift Scenario
Example for AWS Glue.",
                    name: crawlerName,
                    role: iamRole,
                    schedule: cronSchedule,
                    tablePrefix: tablePrefix,
                    targets: targetList
                )
            )
        } catch _ as AlreadyExistsException {
            print("*** A crawler named \"\(crawlerName)\" already exists.")
            return false
        } catch _ as OperationTimeoutException {
            print("*** The attempt to create the AWS Glue crawler timed out.")
            return false
        } catch {
            print("*** An unexpected error occurred creating the AWS Glue
crawler: \(error.localizedDescription)")
            return false
        }

        return true
    }

    /// Delete an AWS Glue crawler.
    ///
    /// - Parameters:

```

```
/// - glueClient: The AWS Glue client to use.
/// - name: The name of the crawler to delete.
///
/// - Returns: `true` if successful, otherwise `false`.
func deleteCrawler(glueClient: GlueClient, name: String) async -> Bool {
    do {
        _ = try await glueClient.deleteCrawler(
            input: DeleteCrawlerInput(name: name)
        )
    } catch {
        return false
    }
    return true
}

/// Start running an AWS Glue crawler.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use when starting the crawler.
///   - name: The name of the crawler to start running.
///
/// - Returns: `true` if the crawler is started successfully, otherwise
`false`.
func startCrawler(glueClient: GlueClient, name: String) async -> Bool {
    do {
        _ = try await glueClient.startCrawler(
            input: StartCrawlerInput(name: name)
        )
    } catch {
        print("*** An unexpected error occurred starting the crawler.")
        return false
    }

    return true
}

/// Get the state of the specified AWS Glue crawler.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - name: The name of the crawler whose state should be returned.
///
/// - Returns: A `GlueClientTypes.CrawlerState` value describing the
state of the crawler.
```

```

func getCrawlerState(glueClient: GlueClient, name: String) async ->
GlueClientTypes.CrawlerState {
    do {
        let output = try await glueClient.getCrawler(
            input: GetCrawlerInput(name: name)
        )

        // If the crawler or its state is `nil`, report that the crawler
        // is stopping. This may not be what you want for your
        // application but it works for this one!

        guard let crawler = output.crawler else {
            return GlueClientTypes.CrawlerState.stopping
        }
        guard let state = crawler.state else {
            return GlueClientTypes.CrawlerState.stopping
        }
        return state
    } catch {
        return GlueClientTypes.CrawlerState.stopping
    }
}

/// Wait until the specified crawler is ready to run.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - name: The name of the crawler to wait for.
///
/// - Returns: `true` if the crawler is ready, `false` if the client is
///   stopping (and will therefore never be ready).
func waitUntilCrawlerReady(glueClient: GlueClient, name: String) async ->
Bool {
    while true {
        let state = await getCrawlerState(glueClient: glueClient, name: name)

        if state == .ready {
            return true
        } else if state == .stopping {
            return false
        }
        Thread.sleep(forTimeInterval: 4)
    }
}

```

```

/// Create a new AWS Glue job.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - jobName: The name to give the new job.
///   - role: The IAM role for the job to use when accessing AWS services.
///   - scriptLocation: The AWS S3 URI of the script to be run by the job.
///
/// - Returns: `true` if the job is created successfully, otherwise `false`.
func createJob(glueClient: GlueClient, name jobName: String, role: String,
               scriptLocation: String) async -> Bool {
    let command = GlueClientTypes.JobCommand(
        name: "glueetl",
        pythonVersion: "3",
        scriptLocation: scriptLocation
    )

    do {
        _ = try await glueClient.createJob(
            input: CreateJobInput(
                command: command,
                description: "Created by the AWS SDK for Swift Glue basic
scenario example.",
                glueVersion: "3.0",
                name: jobName,
                numberOfWorkers: 10,
                role: role,
                workerType: .g1x
            )
        )
    } catch {
        return false
    }
    return true
}

/// Return a list of the AWS Glue jobs listed on the user's account.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - maxJobs: The maximum number of jobs to return (default: 100).
///
/// - Returns: An array of strings listing the names of all available AWS

```

```
/// Glue jobs.
func listJobs(glueClient: GlueClient, maxJobs: Int = 100) async -> [String] {
    var jobList: [String] = []
    var nextToken: String?

    repeat {
        do {
            let output = try await glueClient.listJobs(
                input: ListJobsInput(
                    maxResults: maxJobs,
                    nextToken: nextToken
                )
            )

            guard let jobs = output.jobNames else {
                return jobList
            }

            jobList = jobList + jobs
            nextToken = output.nextToken
        } catch {
            return jobList
        }
    } while (nextToken != nil)

    return jobList
}

/// Delete an AWS Glue job.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - jobName: The name of the job to delete.
///
/// - Returns: `true` if the job is successfully deleted, otherwise `false`.
func deleteJob(glueClient: GlueClient, name jobName: String) async -> Bool {
    do {
        _ = try await glueClient.deleteJob(
            input: DeleteJobInput(jobName: jobName)
        )
    } catch {
        return false
    }
    return true
}
```



```

    }

    /// Create an AWS Glue database.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - databaseName: The name to give the new database.
    ///   - location: The URL of the source data to use with AWS Glue.
    ///
    /// - Returns: `true` if the database is created successfully, otherwise
    /// `false`.
    func createDatabase(glueClient: GlueClient, name databaseName: String,
location: String) async -> Bool {
        let databaseInput = GlueClientTypes.DatabaseInput(
            description: "Created by the AWS SDK for Swift Glue basic scenario
example.",
            locationUri: location,
            name: databaseName
        )

        do {
            _ = try await glueClient.createDatabase(
                input: CreateDatabaseInput(
                    databaseInput: databaseInput
                )
            )
        } catch {
            return false
        }

        return true
    }

    /// Get the AWS Glue database with the specified name.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - name: The name of the database to return.
    ///
    /// - Returns: The `GlueClientTypes.Database` object describing the
    /// specified database, or `nil` if an error occurs or the database
    /// isn't found.
    func getDatabase(glueClient: GlueClient, name: String) async ->
GlueClientTypes.Database? {

```

```

    do {
        let output = try await glueClient.getDatabase(
            input: GetDatabaseInput(name: name)
        )

        return output.database
    } catch {
        return nil
    }
}

/// Returns a list of the tables in the specified database.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - dbName: The name of the database whose tables are to be
///     returned.
///
/// - Returns: An array of `GlueClientTypes.Table` objects, each
///   describing one table in the named database. An empty array indicates
///   that there are either no tables in the database, or an error
///   occurred before any tables could be found.
func getTablesInDatabase(glueClient: GlueClient, dbName: String) async
-> [GlueClientTypes.Table] {
    var tables: [GlueClientTypes.Table] = []
    var nextToken: String?

    repeat {
        do {
            let output = try await glueClient.getTables(
                input: GetTablesInput(
                    dbName: dbName,
                    nextToken: nextToken
                )
            )

            guard let tableList = output.tableList else {
                return tables
            }

            tables = tables + tableList
            nextToken = output.nextToken
        } catch {
            return tables
        }
    } while nextToken != nil
}

```

```

    }
    } while nextToken != nil

    return tables
}

/// Delete the specified database.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - databaseName: The name of the database to delete.
///   - deleteTables: A Bool indicating whether or not to delete the
///     tables in the database before attempting to delete the database.
///
/// - Returns: `true` if the database (and optionally its tables) are
///   deleted, otherwise `false`.
func deleteDatabase(glueClient: GlueClient, name databaseName: String,
                   withTables deleteTables: Bool = false) async -> Bool {
    if deleteTables {
        var tableNames: [String] = []

        // Get a list of the names of all of the tables in the database.

        let tableList = await self.getTablesInDatabase(glueClient:
glueClient, databaseName: databaseName)
        for table in tableList {
            guard let name = table.name else {
                continue
            }
            tableNames.append(name)
        }

        // Delete the tables.

        do {
            _ = try await glueClient.batchDeleteTable(
                input: BatchDeleteTableInput(
                    databaseName: databaseName,
                    tablesToDelete: tableNames
                )
            )
        } catch {
            print("*** Unable to delete the tables.")
        }
    }
}

```

```

        return true
    }

    // Delete the database itself.

    do {
        _ = try await glueClient.deleteDatabase(
            input: DeleteDatabaseInput(name: databaseName)
        )
    } catch {
        print("*** Unable to delete the database.")
    }
    return true
}

/// Start an AWS Glue job run.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - jobName: The name of the job to run.
///   - databaseName: The name of the AWS Glue database to run the job
against.
///   - tableName: The name of the table in the database to run the job
against.
///   - outputURL: The AWS S3 URI of the bucket location into which to
///     write the resulting output.
///
/// - Returns: `true` if the job run is started successfully, otherwise
`false`.
func startJobRun(glueClient: GlueClient, name jobName: String, databaseName:
String,
                tableName: String, outputURL: String) async -> String? {
    do {
        let output = try await glueClient.startJobRun(
            input: StartJobRunInput(
                arguments: [
                    "--input_database": databaseName,
                    "--input_table": tableName,
                    "--output_bucket_url": outputURL
                ],
                jobName: jobName,
                numberOfWorkers: 10,
                workerType: .g1x
            )
        )
    }
}

```

```

        )

        guard let id = output.jobRunId else {
            return nil
        }

        return id
    } catch {
        return nil
    }
}

/// Get information about a specific AWS Glue job run.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - jobName: The name of the job to return job run data for.
///   - id: The run ID of the specific job run to return.
///
/// - Returns: A `GlueClientTypes.JobRun` object describing the state of
///   the job run, or `nil` if an error occurs.
func getJobRun(glueClient: GlueClient, name jobName: String, id: String)
async -> GlueClientTypes.JobRun? {
    do {
        let output = try await glueClient.getJobRun(
            input: GetJobRunInput(
                jobName: jobName,
                runId: id
            )
        )

        return output.jobRun
    } catch {
        return nil
    }
}

/// Called by ``main()`` to run the bulk of the example.
func runAsync() async throws {
    // A name to give the Python script upon upload to the Amazon S3
    // bucket.
    let scriptName = "jobscript.py"

    // Schedule string in `cron` format, as described here:

```

```

// https://docs.aws.amazon.com/glue/latest/dg/monitor-data-warehouse-
schedule.html
let cron = "cron(15 12 * * ? *)"

let glueConfig = try await GlueClient.GlueClientConfiguration(region:
awsRegion)
let glueClient = GlueClient(config: glueConfig)

let s3Config = try await S3Client.S3ClientConfiguration(region:
awsRegion)
let s3Client = S3Client(config: s3Config)

// Create random names for things that need them.

let crawlerName = tempName(prefix: "swift-glue-basics-crawler")
let databaseName = tempName(prefix: "swift-glue-basics-db")

// Create a name for the AWS Glue job.

let jobName = tempName(prefix: "scenario-job")

// The URL of the Python script on S3.

let scriptURL = "s3://\(bucket)/\(scriptName)"

print("Welcome to the AWS SDK for Swift basic scenario for AWS Glue!")

//=====
// 0. Upload the Python script to the target bucket so it's available
//    for use by the Amazon Glue service.
//=====

print("Uploading the Python script: \(script) as key \(scriptName)")
print("Destination bucket: \(bucket)")
if !(await uploadFile(s3Client: s3Client, path: script, toBucket: bucket,
key: scriptName)) {
    return
}

//=====
// 1. Create the database and crawler using the randomized names
//    generated previously.
//=====

```

```

        print("Creating database \"\"(databaseName)\""...")
        if !(await createDatabase(glueClient: glueClient, name: databaseName,
location: s3url)) {
            print("*** Unable to create the database.")
            return
        }

        print("Creating crawler \"\"(crawlerName)\""...")
        if !(await createCrawler(glueClient: glueClient, crawlerName:
crawlerName,
                                iamRole: role, s3Path: s3url, cronSchedule:
cron,
                                databaseName: databaseName)) {
            return
        }

        //=====
        // 2. Start the crawler, then wait for it to be ready.
        //=====

        print("Starting the crawler and waiting until it's ready...")
        if !(await startCrawler(glueClient: glueClient, name: crawlerName)) {
            _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
            return
        }

        if !(await waitUntilCrawlerReady(glueClient: glueClient, name:
crawlerName)) {
            _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
        }

        //=====
        // 3. Get the database and table created by the crawler.
        //=====

        print("Getting the crawler's database...")
        let database = await getDatabase(glueClient: glueClient, name:
databaseName)
        let tableList = await getTablesInDatabase(glueClient: glueClient,
databaseName: databaseName)

        print("Found \"(tableList.count) table(s):")
        for table in tableList {
            print("  \"(table.name ?? "<unnamed>")")

```

```

    }

    if tableList.count != 1 {
        print("**** Incorrect number of tables found. There should only be
one.")
        _ = await deleteDatabase(glueClient: glueClient, name: databaseName,
withTables: true)
        _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
        return
    }

    guard let tableName = tableList[0].name else {
        print("**** Table is unnamed.")
        _ = await deleteDatabase(glueClient: glueClient, name: databaseName,
withTables: true)
        _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
        return
    }

    //=====
    // 4. Create a job.
    //=====

    print("Creating a job...")
    if !(await createJob(glueClient: glueClient, name: jobName, role: role,
                        scriptLocation: scriptURL)) {
        _ = await deleteDatabase(glueClient: glueClient, name: databaseName,
withTables: true)
        _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
        return
    }

    //=====
    // 5. Start a job run.
    //=====

    print("Starting the job...")

    // Construct the Amazon S3 URL for the job run's output. This is in
    // the bucket specified on the command line, with a folder name that's
    // unique for this job run.

    let timeStamp = Date().timeIntervalSince1970
    let jobPath = "\(jobName)-\(Int(timeStamp))"

```



```

let outputURL = "s3://\(bucket)/\(jobPath)"

// Start the job run.

let jobRunID = await startJobRun(glueClient: glueClient, name: jobName,
                                databaseName: databaseName,
                                tableName: tableName,
                                outputURL: outputURL)

guard let jobRunID else {
    print("*** Job run ID is invalid.")
    _ = await deleteJob(glueClient: glueClient, name: jobName)
    _ = await deleteDatabase(glueClient: glueClient, name: databaseName,
withTables: true)
    _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
    return
}

//=====
// 6. Wait for the job run to indicate that the run is complete.
//=====

print("Waiting for job run to end...")

var jobRunFinished = false
var jobRunState: GlueClientTypes.JobRunState

repeat {
    let jobRun = await getJobRun(glueClient: glueClient, name: jobName,
id: jobRunID)
    guard let jobRun else {
        print("*** Unable to get the job run.")
        _ = await deleteJob(glueClient: glueClient, name: jobName)
        _ = await deleteDatabase(glueClient: glueClient, name:
databaseName, withTables: true)
        _ = await deleteCrawler(glueClient: glueClient, name:
crawlerName)
        return
    }
    jobRunState = jobRun.jobRunState ?? .failed

    //
=====
    // 7. Output where to find the data if the job run was successful.

```

```

        //    If the job run failed for any reason, output an appropriate
        //    error message.
        //
=====

        switch jobRunState {
            case .succeeded:
                print("Job run succeeded. JSON files are in the Amazon S3
path:")

                print("    \$(outputURL)")
                jobRunFinished = true
            case .stopped:
                jobRunFinished = true
            case .error:
                print("*** Error: Job run ended in an error.
\$(jobRun.errorMessage ?? "")")
                jobRunFinished = true
            case .failed:
                print("*** Error: Job run failed. \$(jobRun.errorMessage ??
"")")

                jobRunFinished = true
            case .timeout:
                print("*** Warning: Job run timed out.")
                jobRunFinished = true
            default:
                Thread.sleep(forTimeInterval: 0.25)
        }
    } while jobRunFinished != true

//=====
// 8. List the jobs for the user's account.
//=====

print("\nThe account has the following jobs:")
let jobs = await listJobs(glueClient: glueClient)

if jobs.count == 0 {
    print("    <no jobs found>")
} else {
    for job in jobs {
        print("    \$(job)")
    }
}

```

```

//=====
// 9. Get the job run details for a job run.
//=====

print("Information about the job run:")
let jobRun = await getJobRun(glueClient: glueClient, name: jobName, id:
jobRunID)

guard let jobRun else {
    print("*** Unable to retrieve the job run.")
    _ = await deleteJob(glueClient: glueClient, name: jobName)
    _ = await deleteDatabase(glueClient: glueClient, name: databaseName,
withTables: true)
    _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
    return
}

let startDate = jobRun.startedOn ?? Date(timeIntervalSince1970: 0)
let endDate = jobRun.completedOn ?? Date(timeIntervalSince1970: 0)
let dateFormatter: DateFormatter = DateFormatter()
dateFormatter.dateFormat = ".long"
dateFormatter.timeStyle = .long

print("    Started at: \(dateFormatter.string(from: startDate))")
print("    Completed at: \(dateFormatter.string(from: endDate))")

//=====
// 10. Delete the job.
//=====

print("\nDeleting the job...")
_ = await deleteJob(glueClient: glueClient, name: jobName)

//=====
// 11. Delete the database and tables created by this example.
//=====

print("Deleting the database...")
_ = await deleteDatabase(glueClient: glueClient, name: databaseName,
withTables: true)

//=====
// 12. Delete the crawler.
//=====

```

```
        print("Deleting the crawler...")
        if !(await deleteCrawler(glueClient: glueClient, name: crawlerName)) {
            return
        }
    }
}

/// The program's asynchronous entry point.
@main
struct Main {
    static func main() async {
        let args = Array(CommandLine.arguments.dropFirst())

        do {
            let command = try ExampleCommand.parse(args)
            try await command.runAsync()
        } catch {
            ExampleCommand.exit(withError: error)
        }
    }
}
```

- Pour plus d'informations sur l'API, consultez les rubriques suivantes dans la référence de l'API du kit SDK AWS pour Swift.
 - [CreateCrawler](#)
 - [CreateJob](#)
 - [DeleteCrawler](#)
 - [DeleteDatabase](#)
 - [DeleteJob](#)
 - [DeleteTable](#)
 - [GetCrawler](#)
 - [GetDatabase](#)
 - [GetDatabases](#)
 - [GetJob](#)
 - [GetJobRun](#)
 - [GetJobRuns](#)

- [GetTables](#)
- [ListJobs](#)
- [StartCrawler](#)
- [StartJobRun](#)

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Actions d' AWS Glue utilisation AWS SDKs

Les exemples de code suivants montrent comment effectuer des AWS Glue actions individuelles avec AWS SDKs. Chaque exemple inclut un lien vers GitHub, où vous pouvez trouver des instructions pour configurer et exécuter le code.

Les exemples suivants incluent uniquement les actions les plus couramment utilisées. Pour obtenir la liste complète, veuillez consulter la [AWS Glue Référence d'API](#).

Exemples

- [Utilisation CreateCrawler avec un AWS SDK](#)
- [Utilisation CreateJob avec un AWS SDK ou une CLI](#)
- [Utilisation DeleteCrawler avec un AWS SDK](#)
- [Utilisation DeleteDatabase avec un AWS SDK](#)
- [Utilisation DeleteJob avec un AWS SDK ou une CLI](#)
- [Utilisation DeleteTable avec un AWS SDK](#)
- [Utilisation GetCrawler avec un AWS SDK](#)
- [Utilisation GetDatabase avec un AWS SDK](#)
- [Utilisation GetDatabases avec un AWS SDK ou une CLI](#)
- [Utilisation GetJob avec un AWS SDK ou une CLI](#)
- [Utilisation GetJobRun avec un AWS SDK ou une CLI](#)
- [Utilisation GetJobRuns avec un AWS SDK ou une CLI](#)
- [Utilisation GetTables avec un AWS SDK ou une CLI](#)
- [Utilisation ListJobs avec un AWS SDK](#)

- [Utilisation StartCrawler avec un AWS SDK ou une CLI](#)
- [Utilisation StartJobRun avec un AWS SDK ou une CLI](#)

Utilisation **CreateCrawler** avec un AWS SDK

Les exemples de code suivants illustrent comment utiliser CreateCrawler.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>
/// Create an AWS Glue crawler.
/// </summary>
/// <param name="crawlerName">The name for the crawler.</param>
/// <param name="crawlerDescription">A description of the crawler.</param>
/// <param name="role">The AWS Identity and Access Management (IAM) role to
/// be assumed by the crawler.</param>
/// <param name="schedule">The schedule on which the crawler will be
executed.</param>
/// <param name="s3Path">The path to the Amazon Simple Storage Service
(Amazon S3)
/// bucket where the Python script has been stored.</param>
/// <param name="dbName">The name to use for the database that will be
/// created by the crawler.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> CreateCrawlerAsync(
    string crawlerName,
```

```
        string crawlerDescription,
        string role,
        string schedule,
        string s3Path,
        string dbName)
    {
        var s3Target = new S3Target
        {
            Path = s3Path,
        };

        var targetList = new List<S3Target>
        {
            s3Target,
        };

        var targets = new CrawlerTargets
        {
            S3Targets = targetList,
        };

        var crawlerRequest = new CreateCrawlerRequest
        {
            DatabaseName = dbName,
            Name = crawlerName,
            Description = crawlerDescription,
            Targets = targets,
            Role = role,
            Schedule = schedule,
        };

        var response = await _amazonGlue.CreateCrawlerAsync(crawlerRequest);
        return response.HttpStatusCode == System.Net.HttpStatusCode.OK;
    }
```

- Pour plus de détails sur l'API, reportez-vous [CreateCrawler](#) à la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

 Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

    Aws::Client::ClientConfiguration clientConfig;
    // Optional: Set to the AWS Region in which the bucket was created
    (overrides config file).
    // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

    Aws::Glue::Model::S3Target s3Target;
    s3Target.SetPath("s3://crawler-public-us-east-1/flight/2016/csv");
    Aws::Glue::Model::CrawlerTargets crawlerTargets;
    crawlerTargets.AddS3Targets(s3Target);

    Aws::Glue::Model::CreateCrawlerRequest request;
    request.SetTargets(crawlerTargets);
    request.SetName(CRAWLER_NAME);
    request.SetDatabaseName(CRAWLER_DATABASE_NAME);
    request.SetTablePrefix(CRAWLER_DATABASE_PREFIX);
    request.SetRole(roleArn);

    Aws::Glue::Model::CreateCrawlerOutcome outcome =
    client.CreateCrawler(request);

    if (outcome.IsSuccess()) {
        std::cout << "Successfully created the crawler." << std::endl;
    }
    else {
        std::cerr << "Error creating a crawler. " <<
outcome.GetError().GetMessage()
        << std::endl;
        deleteAssets("", CRAWLER_DATABASE_NAME, "", bucketName,
clientConfig);
        return false;
    }

```



```
}
```

- Pour plus de détails sur l'API, reportez-vous [CreateCrawler](#) à la section Référence des AWS SDK pour C++ API.

Java

SDK pour Java 2.x

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/**
 * Creates a new AWS Glue crawler using the AWS Glue Java API.
 *
 * @param glueClient the AWS Glue client used to interact with the AWS Glue
service
 * @param iam        the IAM role that the crawler will use to access the
data source
 * @param s3Path      the S3 path that the crawler will scan for data
 * @param cron        the cron expression that defines the crawler's schedule
 * @param dbName      the name of the AWS Glue database where the crawler
will store the metadata
 * @param crawlerName the name of the crawler to be created
 */
public static void createGlueCrawler(GlueClient glueClient,
                                     String iam,
                                     String s3Path,
                                     String cron,
                                     String dbName,
                                     String crawlerName) {

    try {
        S3Target s3Target = S3Target.builder()
            .path(s3Path)
            .build();
```

```
List<S3Target> targetList = new ArrayList<>();
targetList.add(s3Target);
CrawlerTargets targets = CrawlerTargets.builder()
    .s3Targets(targetList)
    .build();

CreateCrawlerRequest crawlerRequest = CreateCrawlerRequest.builder()
    .databaseName(dbName)
    .name(crawlerName)
    .description("Created by the AWS Glue Java API")
    .targets(targets)
    .role(iam)
    .schedule(cron)
    .build();

glueClient.createCrawler(crawlerRequest);
System.out.println(crawlerName + " was successfully created");

} catch (GlueException e) {
    throw e;
}
}
```

- Pour plus de détails sur l'API, reportez-vous [CreateCrawler](#) à la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const createCrawler = (name, role, dbName, tablePrefix, s3TargetPath) => {
    const client = new GlueClient({});
```

```
const command = new CreateCrawlerCommand({
  Name: name,
  Role: role,
  DatabaseName: dbName,
  TablePrefix: tablePrefix,
  Targets: {
    S3Targets: [{ Path: s3TargetPath }],
  },
});

return client.send(command);
};
```

- Pour plus de détails sur l'API, reportez-vous [CreateCrawler](#) à la section Référence des AWS SDK pour JavaScript API.

Kotlin

SDK pour Kotlin

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
suspend fun createGlueCrawler(
  iam: String?,
  s3Path: String?,
  cron: String?,
  dbName: String?,
  crawlerName: String,
) {
  val s3Target =
    S3Target {
      path = s3Path
    }

  // Add the S3Target to a list.
  val targetList = mutableListOf<S3Target>()
```

```
targetList.add(s3Target)

val target0b =
    CrawlerTargets {
        s3Targets = targetList
    }

val request =
    CreateCrawlerRequest {
        databaseName = dbName
        name = crawlerName
        description = "Created by the AWS Glue Kotlin API"
        targets = target0b
        role = iam
        schedule = cron
    }

GlueClient { region = "us-west-2" }.use { glueClient ->
    glueClient.createCrawler(request)
    println("$crawlerName was successfully created")
}
}
```

- Pour plus de détails sur l'API, reportez-vous [CreateCrawler](#) à la section AWS SDK pour la référence de l'API Kotlin.

PHP

Kit SDK pour PHP

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
$crawlerName = "example-crawler-test-" . $uniqid;

$role = $iamService->getRole("AWSGlueServiceRole-DocExample");
```

```

    $path = 's3://crawler-public-us-east-1/flight/2016/csv';
    $glueService->createCrawler($crawlerName, $role['Role']['Arn'],
    $databaseName, $path);

    public function createCrawler($crawlerName, $role, $databaseName, $path):
    Result
    {
        return $this->customWaiter(function () use ($crawlerName, $role,
    $databaseName, $path) {
            return $this->glueClient->createCrawler([
                'Name' => $crawlerName,
                'Role' => $role,
                'DatabaseName' => $databaseName,
                'Targets' => [
                    'S3Targets' =>
                        [[
                            'Path' => $path,
                        ]]
                ],
            ]);
        });
    }

```

- Pour plus de détails sur l'API, reportez-vous [CreateCrawler](#) à la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):

```

```

        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def create_crawler(self, name, role_arn, db_name, db_prefix, s3_target):
        """
        Creates a crawler that can crawl the specified target and populate a
        database in your AWS Glue Data Catalog with metadata that describes the
data
        in the target.

        :param name: The name of the crawler.
        :param role_arn: The Amazon Resource Name (ARN) of an AWS Identity and
Access
                        Management (IAM) role that grants permission to let AWS
Glue
                        access the resources it needs.
        :param db_name: The name to give the database that is created by the
crawler.
        :param db_prefix: The prefix to give any database tables that are created
by
                        the crawler.
        :param s3_target: The URL to an S3 bucket that contains data that is
                        the target of the crawler.
        """
        try:
            self.glue_client.create_crawler(
                Name=name,
                Role=role_arn,
                DatabaseName=db_name,
                TablePrefix=db_prefix,
                Targets={"S3Targets": [{"Path": s3_target}]},
            )
        except ClientError as err:
            logger.error(
                "Couldn't create crawler. Here's why: %s: %s",
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise

```

- Pour plus de détails sur l'API, consultez [CreateCrawler](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Creates a new crawler with the specified configuration.
  #
  # @param name [String] The name of the crawler.
  # @param role_arn [String] The ARN of the IAM role to be used by the crawler.
  # @param db_name [String] The name of the database where the crawler stores its
  # metadata.
  # @param db_prefix [String] The prefix to be added to the names of tables that
  # the crawler creates.
  # @param s3_target [String] The S3 path that the crawler will crawl.
  # @return [void]
  def create_crawler(name, role_arn, db_name, _db_prefix, s3_target)
    @glue_client.create_crawler(
      name: name,
```

```

    role: role_arn,
    database_name: db_name,
    targets: {
      s3_targets: [
        {
          path: s3_target
        }
      ]
    }
  )
rescue Aws::Glue::Errors::GlueException => e
  @logger.error("Glue could not create crawler: \n#{e.message}")
  raise
end

```

- Pour plus de détails sur l'API, reportez-vous [CreateCrawler](#) à la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

let create_crawler = glue
  .create_crawler()
  .name(self.crawler())
  .database_name(self.database())
  .role(self.iam_role.expose_secret())
  .targets(
    CrawlerTargets::builder()
      .s3_targets(S3Target::builder().path(CRAWLER_TARGET).build())
      .build(),
  )
  .send()
  .await;

```



```

match create_crawler {
  Err(err) => {
    let glue_err: aws_sdk_glue::Error = err.into();
    match glue_err {
      aws_sdk_glue::Error::AlreadyExistsException(_) => {
        info!("Using existing crawler");
        Ok(())
      }
      _ => Err(GlueMvpError::GlueSdk(glue_err)),
    }
  }
  Ok(_) => Ok(()),
}??;

```

- Pour plus de détails sur l'API, voir [CreateCrawler](#) la section de référence de l'API AWS SDK for Rust.

Swift

Kit SDK pour Swift

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

import AWSClientRuntime
import AWSGlue

/// Create a new AWS Glue crawler.
///
/// - Parameters:
///   - glueClient: An AWS Glue client to use for the crawler.
///   - crawlerName: A name for the new crawler.
///   - iamRole: The name of an Amazon IAM role for the crawler to use.
///   - s3Path: The path of an Amazon S3 folder to use as a target location.
///   - cronSchedule: A `cron` schedule indicating when to run the crawler.
///   - databaseName: The name of an AWS Glue database to operate on.

```

```

    ///
    /// - Returns: `true` if the crawler is created successfully, otherwise
    `false`.
    func createCrawler(glueClient: GlueClient, crawlerName: String, iamRole:
String,
                        s3Path: String, cronSchedule: String, databaseName:
String) async -> Bool {
        let s3Target = GlueClientTypes.S3Target(path: s3url)
        let targetList = GlueClientTypes.CrawlerTargets(s3Targets: [s3Target])

        do {
            _ = try await glueClient.createCrawler(
                input: CreateCrawlerInput(
                    databaseName: databaseName,
                    description: "Created by the AWS SDK for Swift Scenario
Example for AWS Glue.",
                    name: crawlerName,
                    role: iamRole,
                    schedule: cronSchedule,
                    tablePrefix: tablePrefix,
                    targets: targetList
                )
            )
        } catch _ as AlreadyExistsException {
            print("*** A crawler named \"\"(crawlerName)\" already exists.")
            return false
        } catch _ as OperationTimeoutException {
            print("*** The attempt to create the AWS Glue crawler timed out.")
            return false
        } catch {
            print("*** An unexpected error occurred creating the AWS Glue
crawler: \"(error.localizedDescription)\"")
            return false
        }

        return true
    }

```

- Pour plus de détails sur l'API, reportez-vous [CreateCrawler](#) à la section AWS SDK pour la référence de l'API Swift.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **CreateJob** avec un AWS SDK ou une CLI

Les exemples de code suivants illustrent comment utiliser CreateJob.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>
/// Create an AWS Glue job.
/// </summary>
/// <param name="jobName">The name of the job.</param>
/// <param name="roleName">The name of the IAM role to be assumed by
/// the job.</param>
/// <param name="description">A description of the job.</param>
/// <param name="scriptUrl">The URL to the script.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> CreateJobAsync(string dbName, string tableName,
string bucketUrl, string jobName, string roleName, string description, string
scriptUrl)
{
    var command = new JobCommand
    {
        PythonVersion = "3",
```

```
        Name = "glueetl",
        ScriptLocation = scriptUrl,
    };

    var arguments = new Dictionary<string, string>
    {
        { "--input_database", dbName },
        { "--input_table", tableName },
        { "--output_bucket_url", bucketUrl }
    };

    var request = new CreateJobRequest
    {
        Command = command,
        DefaultArguments = arguments,
        Description = description,
        GlueVersion = "3.0",
        Name = jobName,
        NumberOfWorkers = 10,
        Role = roleName,
        WorkerType = "G.1X"
    };

    var response = await _amazonGlue.CreateJobAsync(request);
    return response.HttpStatusCode == HttpStatusCode.OK;
}
```

- Pour plus de détails sur l'API, reportez-vous [CreateJob](#) à la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

    Aws::Client::ClientConfiguration clientConfig;
    // Optional: Set to the AWS Region in which the bucket was created
    (overrides config file).
    // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

    Aws::Glue::Model::CreateJobRequest request;
    request.SetName(JOB_NAME);
    request.SetRole(roleArn);
    request.SetGlueVersion(GLUE_VERSION);

    Aws::Glue::Model::JobCommand command;
    command.SetName(JOB_COMMAND_NAME);
    command.SetPythonVersion(JOB_PYTHON_VERSION);
    command.SetScriptLocation(
        Aws::String("s3://") + bucketName + "/" + PYTHON_SCRIPT);
    request.SetCommand(command);

    Aws::Glue::Model::CreateJobOutcome outcome = client.CreateJob(request);

    if (outcome.IsSuccess()) {
        std::cout << "Successfully created the job." << std::endl;
    }
    else {
        std::cerr << "Error creating the job. " <<
outcome.GetError().GetMessage()
        << std::endl;
        deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
            clientConfig);
        return false;
    }
}

```

- Pour plus de détails sur l'API, reportez-vous [CreateJob](#) à la section Référence des AWS SDK pour C++ API.

CLI

AWS CLI

Pour créer une tâche afin de transformer des données

L'exemple `create-job` suivant crée une tâche de streaming qui exécute un script stocké dans S3.

```
aws glue create-job \
  --name my-testing-job \
  --role AWSGlueServiceRoleDefault \
  --command '{ \
    "Name": "gluestreaming", \
    "ScriptLocation": "s3://amzn-s3-demo-bucket/folder/" \
  }' \
  --region us-east-1 \
  --output json \
  --default-arguments '{ \
    "--job-language":"scala", \
    "--class":"GlueApp" \
  }' \
  --profile my-profile \
  --endpoint https://glue.us-east-1.amazonaws.com
```

Contenu de `test_script.scala` :

```
import com.amazonaws.services.glue.ChoiceOption
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.ResolveSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    // @params: [JOB_NAME]
    val args = GlueArgParser.getResolvedOptions(sysArgs,
Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
    // @type: DataSource
    // @args: [database = "tempdb", table_name = "s3-source",
transformation_ctx = "datasource0"]
```

```

        // @return: datasource0
        // @inputs: []
        val datasource0 = glueContext.getCatalogSource(database = "tempdb",
        tableName = "s3-source", redshiftTmpDir = "", transformationContext =
        "datasource0").getDynamicFrame()
        // @type: ApplyMapping
        // @args: [mapping = [("sensorid", "int", "sensorid", "int"),
        ("currenttemperature", "int", "currenttemperature", "int"), ("status", "string",
        "status", "string")], transformation_ctx = "applymapping1"]
        // @return: applymapping1
        // @inputs: [frame = datasource0]
        val applymapping1 = datasource0.applyMapping(mappings = Seq(("sensorid",
        "int", "sensorid", "int"), ("currenttemperature", "int", "currenttemperature",
        "int"), ("status", "string", "status", "string")), caseSensitive = false,
        transformationContext = "applymapping1")
        // @type: SelectFields
        // @args: [paths = ["sensorid", "currenttemperature", "status"],
        transformation_ctx = "selectfields2"]
        // @return: selectfields2
        // @inputs: [frame = applymapping1]
        val selectfields2 = applymapping1.selectFields(paths = Seq("sensorid",
        "currenttemperature", "status"), transformationContext = "selectfields2")
        // @type: ResolveChoice
        // @args: [choice = "MATCH_CATALOG", database = "tempdb", table_name =
        "my-s3-sink", transformation_ctx = "resolvechoice3"]
        // @return: resolvechoice3
        // @inputs: [frame = selectfields2]
        val resolvechoice3 = selectfields2.resolveChoice(choiceOption =
        Some(ChoiceOption("MATCH_CATALOG")), database = Some("tempdb"), tableName =
        Some("my-s3-sink"), transformationContext = "resolvechoice3")
        // @type: DataSink
        // @args: [database = "tempdb", table_name = "my-s3-sink",
        transformation_ctx = "datasink4"]
        // @return: datasink4
        // @inputs: [frame = resolvechoice3]
        val datasink4 = glueContext.getCatalogSink(database = "tempdb",
        tableName = "my-s3-sink", redshiftTmpDir = "", transformationContext =
        "datasink4").writeDynamicFrame(resolvechoice3)
        Job.commit()
    }
}

```

Sortie :

```
{
    "Name": "my-testing-job"
}
```

Pour plus d'informations, consultez la section [Création de jobs dans AWS Glue dans](#) le AWS Glue Developer Guide.

- Pour plus de détails sur l'API, reportez-vous [CreateJob](#) à la section Référence des AWS CLI commandes.

Java

SDK pour Java 2.x

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/**
 * Creates a new AWS Glue job.
 *
 * @param glueClient    the AWS Glue client to use for the operation
 * @param jobName       the name of the job to create
 * @param iam           the IAM role to associate with the job
 * @param scriptLocation the location of the script to be used by the job
 * @throws GlueException if there is an error creating the job
 */
public static void createJob(GlueClient glueClient, String jobName, String
iam, String scriptLocation) {
    try {
        JobCommand command = JobCommand.builder()
            .pythonVersion("3")
            .name("glueetl")
            .scriptLocation(scriptLocation)
            .build();

        CreateJobRequest jobRequest = CreateJobRequest.builder()
            .description("A Job created by using the AWS SDK for Java V2")
```



```
        .glueVersion("2.0")
        .workerType(WorkerType.G_1_X)
        .numberOfWorkers(10)
        .name(jobName)
        .role(iam)
        .command(command)
        .build();

    glueClient.createJob(jobRequest);
    System.out.println(jobName + " was successfully created.");

} catch (GlueException e) {
    throw e;
}
}
```

- Pour plus de détails sur l'API, reportez-vous [CreateJob](#) à la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const createJob = (name, role, scriptBucketName, scriptKey) => {
    const client = new GlueClient({});

    const command = new CreateJobCommand({
        Name: name,
        Role: role,
        Command: {
            Name: "glueetl",
            PythonVersion: "3",
            ScriptLocation: `s3://${scriptBucketName}/${scriptKey}`,
        },
    },
```

```

        GlueVersion: "3.0",
    });

    return client.send(command);
};

```

- Pour plus de détails sur l'API, reportez-vous [CreateJob](#) à la section Référence des AWS SDK pour JavaScript API.

PHP

Kit SDK pour PHP

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

$role = $iamService->getRole("AWSGlueServiceRole-DocExample");

$jobName = 'test-job-' . $uniqid;

$scriptLocation = "s3://$bucketName/run_job.py";
$job = $glueService->createJob($jobName, $role['Role']['Arn'],
$scriptLocation);

public function createJob($jobName, $role, $scriptLocation, $pythonVersion =
'3', $glueVersion = '3.0'): Result
{
    return $this->glueClient->createJob([
        'Name' => $jobName,
        'Role' => $role,
        'Command' => [
            'Name' => 'glueetl',
            'ScriptLocation' => $scriptLocation,
            'PythonVersion' => $pythonVersion,
        ],
        'GlueVersion' => $glueVersion,
    ]);
}

```

```
}
```

- Pour plus de détails sur l'API, reportez-vous [CreateJob](#) à la section Référence des AWS SDK pour PHP API.

PowerShell

Outils pour PowerShell V4

Exemple 1 : Cet exemple crée une nouvelle tâche dans AWS Glue. La valeur du nom de commande est toujours **glueetl**. AWS Glue permet d'exécuter des scripts de travail écrits en Python ou Scala. Dans cet exemple, le script de tâche (MyTestGlueJob.py) est écrit en Python. Les paramètres Python sont spécifiés dans la **\$DefArgs** variable, puis transmis à la PowerShell commande dans le **DefaultArguments** paramètre, qui accepte une table de hachage. Les paramètres de la **\$JobParams** variable proviennent de l' CreateJob API, documentés dans la rubrique Jobs (<https://docs.aws.amazon.com/glue/latest/dg/aws-glue-api-jobs-job.html>) de la référence de l'API AWS Glue.

```
$Command = New-Object Amazon.Glue.Model.JobCommand
$Command.Name = 'glueetl'
$Command.ScriptLocation = 's3://amzn-s3-demo-source-bucket/admin/
MyTestGlueJob.py'
$Command

$Source = "source_test_table"
$Target = "target_test_table"
$Connections = $Source, $Target

$DefArgs = @{
    '--TempDir' = 's3://amzn-s3-demo-bucket/admin'
    '--job-bookmark-option' = 'job-bookmark-disable'
    '--job-language' = 'python'
}
$DefArgs

$ExecutionProp = New-Object Amazon.Glue.Model.ExecutionProperty
$ExecutionProp.MaxConcurrentRuns = 1
$ExecutionProp

$JobParams = @{
```

```

"AllocatedCapacity"    = "5"
"Command"              = $Command
"Connections_Connection" = $Connections
"DefaultArguments"     = $DefArgs
"Description"          = "This is a test"
"ExecutionProperty"    = $ExecutionProp
"MaxRetries"           = "1"
"Name"                 = "MyOregonTestGlueJob"
"Role"                 = "Amazon-GlueServiceRoleForSSM"
"Timeout"              = "20"
}

```

New-GlueJob @JobParams

- Pour plus de détails sur l'API, reportez-vous [CreateJob](#) à la section Référence des Outils AWS pour PowerShell applets de commande (V4).

Outils pour PowerShell V5

Exemple 1 : Cet exemple crée une nouvelle tâche dans AWS Glue. La valeur du nom de commande est toujours **glueetl**. AWS Glue permet d'exécuter des scripts de travail écrits en Python ou Scala. Dans cet exemple, le script de tâche (MyTestGlueJob.py) est écrit en Python. Les paramètres Python sont spécifiés dans la **\$DefArgs** variable, puis transmis à la PowerShell commande dans le **DefaultArguments** paramètre, qui accepte une table de hachage. Les paramètres de la **\$JobParams** variable proviennent de l' CreateJob API, documentés dans la rubrique Jobs (<https://docs.aws.amazon.com/glue/latest/dg/aws-glue-api-jobs-job.html>) de la référence de l'API AWS Glue.

```

$Command = New-Object Amazon.Glue.Model.JobCommand
$Command.Name = 'glueetl'
$Command.ScriptLocation = 's3://amzn-s3-demo-source-bucket/admin/
MyTestGlueJob.py'
$Command

$Source = "source_test_table"
$Target = "target_test_table"
$Connections = $Source, $Target

$DefArgs = @{
    '--TempDir' = 's3://amzn-s3-demo-bucket/admin'
    '--job-bookmark-option' = 'job-bookmark-disable'
    '--job-language' = 'python'
}

```

```

$DefArgs

$ExecutionProp = New-Object Amazon.Glue.Model.ExecutionProperty
$ExecutionProp.MaxConcurrentRuns = 1
$ExecutionProp

$JobParams = @{
    "AllocatedCapacity"    = "5"
    "Command"              = $Command
    "Connections_Connection" = $Connections
    "DefaultArguments"     = $DefArgs
    "Description"          = "This is a test"
    "ExecutionProperty"    = $ExecutionProp
    "MaxRetries"           = "1"
    "Name"                 = "MyOregonTestGlueJob"
    "Role"                 = "Amazon-GlueServiceRoleForSSM"
    "Timeout"              = "20"
}

New-GlueJob @JobParams

```

- Pour plus de détails sur l'API, reportez-vous [CreateJob](#) à la section Référence des Outils AWS pour PowerShell applets de commande (V5).

Python

SDK pour Python (Boto3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """

```

```

        self.glue_client = glue_client

    def create_job(self, name, description, role_arn, script_location):
        """
        Creates a job definition for an extract, transform, and load (ETL) job
        that can
            be run by AWS Glue.

        :param name: The name of the job definition.
        :param description: The description of the job definition.
        :param role_arn: The ARN of an IAM role that grants AWS Glue the
        permissions
            it requires to run the job.
        :param script_location: The Amazon S3 URL of a Python ETL script that is
        run as
            part of the job. The script defines how the data
        is
            transformed.
        """
        try:
            self.glue_client.create_job(
                Name=name,
                Description=description,
                Role=role_arn,
                Command={
                    "Name": "glueetl",
                    "ScriptLocation": script_location,
                    "PythonVersion": "3",
                },
                GlueVersion="3.0",
            )
        except ClientError as err:
            logger.error(
                "Couldn't create job %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise

```

- Pour plus de détails sur l'API, consultez [CreateJob](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Creates a new job with the specified configuration.
  #
  # @param name [String] The name of the job.
  # @param description [String] The description of the job.
  # @param role_arn [String] The ARN of the IAM role to be used by the job.
  # @param script_location [String] The location of the ETL script for the job.
  # @return [void]
  def create_job(name, description, role_arn, script_location)
    @glue_client.create_job(
      name: name,
      description: description,
      role: role_arn,
      command: {
        name: 'glueetl',
        script_location: script_location,
```

```

        python_version: '3'
      },
      glue_version: '3.0'
    )
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not create job #{name}: \n#{e.message}")
    raise
  end
end

```

- Pour plus de détails sur l'API, reportez-vous [CreateJob](#) à la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

let create_job = glue
  .create_job()
  .name(self.job())
  .role(self.iam_role.expose_secret())
  .command(
    JobCommand::builder()
      .name("glueetl")
      .python_version("3")
      .script_location(format!("s3://{}/job.py", self.bucket()))
      .build(),
  )
  .glue_version("3.0")
  .send()
  .await
  .map_err(GlueMvpError::from_glue_sdk)?;

let job_name = create_job.name().ok_or_else(|| {

```



```
GlueMvpError::Unknown("Did not get job name after creating
job".into())
})?;
```

- Pour plus de détails sur l'API, voir [CreateJob](#) la section de référence de l'API AWS SDK for Rust.

Swift

Kit SDK pour Swift

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
import AWSClientRuntime
import AWSGlue

/// Create a new AWS Glue job.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - jobName: The name to give the new job.
///   - role: The IAM role for the job to use when accessing AWS services.
///   - scriptLocation: The AWS S3 URI of the script to be run by the job.
///
/// - Returns: `true` if the job is created successfully, otherwise `false`.
func createJob(glueClient: GlueClient, name jobName: String, role: String,
               scriptLocation: String) async -> Bool {
    let command = GlueClientTypes.JobCommand(
        name: "glueetl",
        pythonVersion: "3",
        scriptLocation: scriptLocation
    )

    do {
        _ = try await glueClient.createJob(
            input: CreateJobInput(
```

```
        command: command,
        description: "Created by the AWS SDK for Swift Glue basic
scenario example.",
        glueVersion: "3.0",
        name: jobName,
        numberOfWorkers: 10,
        role: role,
        workerType: .g1x
    )
}
} catch {
    return false
}
return true
}
```

- Pour plus de détails sur l'API, reportez-vous [CreateJob](#) à la section AWS SDK pour la référence de l'API Swift.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **DeleteCrawler** avec un AWS SDK

Les exemples de code suivants illustrent comment utiliser `DeleteCrawler`.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>
/// Delete an AWS Glue crawler.
/// </summary>
/// <param name="crawlerName">The name of the crawler.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> DeleteCrawlerAsync(string crawlerName)
{
    var response = await _amazonGlue.DeleteCrawlerAsync(new
DeleteCrawlerRequest { Name = crawlerName });
    return response.HttpStatusCode == HttpStatusCode.OK;
}
```

- Pour plus de détails sur l'API, voir [DeleteCrawler](#) la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
Aws::Client::ClientConfiguration clientConfig;
// Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
```

```

        // clientConfig.region = "us-east-1";

        Aws::Glue::GlueClient client(clientConfig);

        Aws::Glue::Model::DeleteCrawlerRequest request;
        request.SetName(crawler);

        Aws::Glue::Model::DeleteCrawlerOutcome outcome =
        client.DeleteCrawler(request);

        if (outcome.IsSuccess()) {
            std::cout << "Successfully deleted the crawler." << std::endl;
        }
        else {
            std::cerr << "Error deleting the crawler. "
                << outcome.GetError().GetMessage() << std::endl;
            result = false;
        }
    }

```

- Pour plus de détails sur l'API, voir [DeleteCrawler](#) la section Référence des AWS SDK pour C++ API.

Java

SDK pour Java 2.x

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

/**
 * Deletes a specific AWS Glue crawler.
 *
 * @param glueClient the AWS Glue client object
 * @param crawlerName the name of the crawler to be deleted
 * @throws GlueException if an error occurs during the deletion process
 */

```

```
public static void deleteSpecificCrawler(GlueClient glueClient, String
crawlerName) {
    try {
        DeleteCrawlerRequest deleteCrawlerRequest =
DeleteCrawlerRequest.builder()
            .name(crawlerName)
            .build();

        glueClient.deleteCrawler(deleteCrawlerRequest);
        System.out.println(crawlerName + " was deleted");

    } catch (GlueException e) {
        throw e;
    }
}
```

- Pour plus de détails sur l'API, voir [DeleteCrawler](#) la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const deleteCrawler = (crawlerName) => {
    const client = new GlueClient({});

    const command = new DeleteCrawlerCommand({
        Name: crawlerName,
    });

    return client.send(command);
};
```

- Pour plus de détails sur l'API, voir [DeleteCrawler](#) la section Référence des AWS SDK pour JavaScript API.

PHP

Kit SDK pour PHP

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
echo "Delete the crawler.\n";
$glueClient->deleteCrawler([
    'Name' => $crawlerName,
]);

public function deleteCrawler($crawlerName)
{
    return $this->glueClient->deleteCrawler([
        'Name' => $crawlerName,
    ]);
}
```

- Pour plus de détails sur l'API, voir [DeleteCrawler](#) la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def delete_crawler(self, name):
        """
        Deletes a crawler.

        :param name: The name of the crawler to delete.
        """
        try:
            self.glue_client.delete_crawler(Name=name)
        except ClientError as err:
            logger.error(
                "Couldn't delete crawler %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
```

- Pour plus de détails sur l'API, consultez [DeleteCrawler](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Deletes a crawler with the specified name.
  #
  # @param name [String] The name of the crawler to delete.
  # @return [void]
  def delete_crawler(name)
    @glue_client.delete_crawler(name: name)
    rescue Aws::Glue::Errors::ServiceError => e
      @logger.error("Glue could not delete crawler #{name}: \n#{e.message}")
      raise
    end
  end
end
```

- Pour plus de détails sur l'API, voir [DeleteCrawler](#) la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
glue.delete_crawler()
    .name(self.crawler())
    .send()
```



```
.await
.map_err(GlueMvpError::from_glue_sdk)?;
```

- Pour plus de détails sur l'API, voir [DeleteCrawler](#) la section de référence de l'API AWS SDK for Rust.

Swift

Kit SDK pour Swift

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
import AWSClientRuntime
import AWSGlue

/// Delete an AWS Glue crawler.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - name: The name of the crawler to delete.
///
/// - Returns: `true` if successful, otherwise `false`.
func deleteCrawler(glueClient: GlueClient, name: String) async -> Bool {
    do {
        _ = try await glueClient.deleteCrawler(
            input: DeleteCrawlerInput(name: name)
        )
    } catch {
        return false
    }
    return true
}
```

- Pour plus de détails sur l'API, reportez-vous [DeleteCrawler](#) à la section AWS SDK pour la référence de l'API Swift.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **DeleteDatabase** avec un AWS SDK

Les exemples de code suivants illustrent comment utiliser DeleteDatabase.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>
/// Delete the AWS Glue database.
/// </summary>
/// <param name="dbName">The name of the database.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> DeleteDatabaseAsync(string dbName)
{
    var response = await _amazonGlue.DeleteDatabaseAsync(new
DeleteDatabaseRequest { Name = dbName });
    return response.HttpStatusCode == HttpStatusCode.OK;
}
```

- Pour plus de détails sur l'API, voir [DeleteDatabase](#) la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

 Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
Aws::Client::ClientConfiguration clientConfig;
// Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
// clientConfig.region = "us-east-1";

Aws::Glue::GlueClient client(clientConfig);

Aws::Glue::Model::DeleteDatabaseRequest request;
request.SetName(database);

Aws::Glue::Model::DeleteDatabaseOutcome outcome = client.DeleteDatabase(
    request);

if (outcome.IsSuccess()) {
    std::cout << "Successfully deleted the database." << std::endl;
}
else {
    std::cerr << "Error deleting database. " <<
outcome.GetError().GetMessage()
    << std::endl;
    result = false;
}
```

- Pour plus de détails sur l'API, voir [DeleteDatabase](#) la section Référence des AWS SDK pour C++ API.

Java

SDK pour Java 2.x

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/**
 * Deletes a AWS Glue Database.
 *
 * @param glueClient  An instance of the AWS Glue client used to interact
with the AWS Glue service.
 * @param databaseName The name of the database to be deleted.
 * @throws GlueException If an error occurs while deleting the database.
 */
public static void deleteDatabase(GlueClient glueClient, String databaseName)
{
    try {
        DeleteDatabaseRequest request = DeleteDatabaseRequest.builder()
            .name(databaseName)
            .build();

        glueClient.deleteDatabase(request);
        System.out.println(databaseName + " was successfully deleted");

    } catch (GlueException e) {
        throw e;
    }
}
```

- Pour plus de détails sur l'API, voir [DeleteDatabase](#) la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const deleteDatabase = (databaseName) => {  
  const client = new GlueClient({});  
  
  const command = new DeleteDatabaseCommand({  
    Name: databaseName,  
  });  
  
  return client.send(command);  
};
```

- Pour plus de détails sur l'API, voir [DeleteDatabase](#) la section Référence des AWS SDK pour JavaScript API.

PHP

Kit SDK pour PHP

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
echo "Delete the databases.\n";  
$glueClient->deleteDatabase([  
  'Name' => $databaseName,  
]);  
  
public function deleteDatabase($databaseName)
```

```
{
    return $this->glueClient->deleteDatabase([
        'Name' => $databaseName,
    ]);
}
```

- Pour plus de détails sur l'API, voir [DeleteDatabase](#) la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def delete_database(self, name):
        """
        Deletes a metadata database from your Data Catalog.

        :param name: The name of the database to delete.
        """
        try:
            self.glue_client.delete_database(Name=name)
        except ClientError as err:
            logger.error(
                "Couldn't delete database %s. Here's why: %s: %s",

```

```

        name,
        err.response["Error"]["Code"],
        err.response["Error"]["Message"],
    )
    raise

```

- Pour plus de détails sur l'API, consultez [DeleteDatabase](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Removes a specified database from a Data Catalog.
  #
  # @param database_name [String] The name of the database to delete.
  # @return [void]
  def delete_database(database_name)
    @glue_client.delete_database(name: database_name)
  rescue Aws::Glue::Errors::ServiceError => e

```

```
@logger.error("Glue could not delete database: \n#{e.message}")
end
```

- Pour plus de détails sur l'API, voir [DeleteDatabase](#) la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
glue.delete_database()
    .name(self.database())
    .send()
    .await
    .map_err(GlueMvpError::from_glue_sdk)?;
```

- Pour plus de détails sur l'API, voir [DeleteDatabase](#) la section de référence de l'API AWS SDK for Rust.

Swift

Kit SDK pour Swift

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
import AWSClientRuntime
import AWSGlue
```



```

/// Delete the specified database.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - databaseName: The name of the database to delete.
///   - deleteTables: A Bool indicating whether or not to delete the
///     tables in the database before attempting to delete the database.
///
/// - Returns: `true` if the database (and optionally its tables) are
///   deleted, otherwise `false`.
func deleteDatabase(glueClient: GlueClient, name databaseName: String,
                   withTables deleteTables: Bool = false) async -> Bool {
    if deleteTables {
        var tableNames: [String] = []

        // Get a list of the names of all of the tables in the database.

        let tableList = await self.getTablesInDatabase(glueClient:
glueClient, databaseName: databaseName)
        for table in tableList {
            guard let name = table.name else {
                continue
            }
            tableNames.append(name)
        }

        // Delete the tables.

        do {
            _ = try await glueClient.batchDeleteTable(
                input: BatchDeleteTableInput(
                    databaseName: databaseName,
                    tablesToDelete: tableNames
                )
            )
        } catch {
            print("*** Unable to delete the tables.")
        }
        return true
    }

    // Delete the database itself.

```

```
do {
    _ = try await glueClient.deleteDatabase(
        input: DeleteDatabaseInput(name: dbName)
    )
} catch {
    print("*** Unable to delete the database.")
}
return true
}
```

- Pour plus de détails sur l'API, reportez-vous [DeleteDatabase](#) à la section AWS SDK pour la référence de l'API Swift.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **DeleteJob** avec un AWS SDK ou une CLI

Les exemples de code suivants illustrent comment utiliser DeleteJob.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>
/// Delete an AWS Glue job.
```

```

    /// </summary>
    /// <param name="jobName">The name of the job.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> DeleteJobAsync(string jobName)
    {
        var response = await _amazonGlue.DeleteJobAsync(new DeleteJobRequest
        { JobName = jobName });
        return response.HttpStatusCode == HttpStatusCode.OK;
    }

```

- Pour plus de détails sur l'API, voir [DeleteJob](#) la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

    Aws::Client::ClientConfiguration clientConfig;
    // Optional: Set to the AWS Region in which the bucket was created
    (overrides config file).
    // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

    Aws::Glue::Model::DeleteJobRequest request;
    request.SetJobName(job);

    Aws::Glue::Model::DeleteJobOutcome outcome = client.DeleteJob(request);

    if (outcome.IsSuccess()) {
        std::cout << "Successfully deleted the job." << std::endl;
    }

```

```
        else {
            std::cerr << "Error deleting the job. " <<
outcome.GetError().GetMessage()
                << std::endl;
            result = false;
        }
```

- Pour plus de détails sur l'API, voir [DeleteJob](#) la section Référence des AWS SDK pour C++ API.

CLI

AWS CLI

Pour supprimer une tâche

L'exemple `delete-job` suivant supprime une tâche qui n'est plus nécessaire.

```
aws glue delete-job \
    --job-name my-testing-job
```

Sortie :

```
{
  "JobName": "my-testing-job"
}
```

Pour plus d'informations, consultez [Working with Jobs on the AWS Glue Console](#) dans le AWS Glue Developer Guide.

- Pour plus de détails sur l'API, reportez-vous [DeleteJob](#) à la section Référence des AWS CLI commandes.

Java

SDK pour Java 2.x

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/**
 * Deletes a Glue job.
 *
 * @param glueClient the Glue client to use for the operation
 * @param jobName    the name of the job to be deleted
 * @throws GlueException if there is an error deleting the job
 */
public static void deleteJob(GlueClient glueClient, String jobName) {
    try {
        DeleteJobRequest jobRequest = DeleteJobRequest.builder()
            .jobName(jobName)
            .build();

        glueClient.deleteJob(jobRequest);
        System.out.println(jobName + " was successfully deleted");

    } catch (GlueException e) {
        throw e;
    }
}
```

- Pour plus de détails sur l'API, voir [DeleteJob](#) la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const deleteJob = (jobName) => {  
  const client = new GlueClient({});  
  
  const command = new DeleteJobCommand({  
    JobName: jobName,  
  });  
  
  return client.send(command);  
};
```

- Pour plus de détails sur l'API, voir [DeleteJob](#) la section Référence des AWS SDK pour JavaScript API.

PHP

Kit SDK pour PHP

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
echo "Delete the job.\n";  
$glueClient->deleteJob([  
  'JobName' => $job['Name'],  
]);  
  
public function deleteJob($jobName)
```

```
{
    return $this->glueClient->deleteJob([
        'JobName' => $jobName,
    ]);
}
```

- Pour plus de détails sur l'API, voir [DeleteJob](#) la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def delete_job(self, job_name):
        """
        Deletes a job definition. This also deletes data about all runs that are
        associated with this job definition.

        :param job_name: The name of the job definition to delete.
        """
        try:
            self.glue_client.delete_job(JobName=job_name)
        except ClientError as err:
            logger.error(
```

```

        "Couldn't delete job %s. Here's why: %s: %s",
        job_name,
        err.response["Error"]["Code"],
        err.response["Error"]["Message"],
    )
    raise

```

- Pour plus de détails sur l'API, consultez [DeleteJob](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Deletes a job with the specified name.
  #
  # @param job_name [String] The name of the job to delete.
  # @return [void]
  def delete_job(job_name)
    @glue_client.delete_job(job_name: job_name)
  end
end

```



```
rescue Aws::Glue::Errors::ServiceError => e
  @logger.error("Glue could not delete job: \n#{e.message}")
end
```

- Pour plus de détails sur l'API, voir [DeleteJob](#) la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
glue.delete_job()
  .job_name(self.job())
  .send()
  .await
  .map_err(GlueMvpError::from_glue_sdk)?;
```

- Pour plus de détails sur l'API, voir [DeleteJob](#) la section de référence de l'API AWS SDK for Rust.

Swift

Kit SDK pour Swift

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
import AWSClientRuntime
```

```
import AWSGlue

/// Delete an AWS Glue job.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - jobName: The name of the job to delete.
///
/// - Returns: `true` if the job is successfully deleted, otherwise `false`.
func deleteJob(glueClient: GlueClient, name jobName: String) async -> Bool {
    do {
        _ = try await glueClient.deleteJob(
            input: DeleteJobInput(jobName: jobName)
        )
    } catch {
        return false
    }
    return true
}
```

- Pour plus de détails sur l'API, reportez-vous [DeleteJob](#) à la section AWS SDK pour la référence de l'API Swift.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **DeleteTable** avec un AWS SDK

Les exemples de code suivants illustrent comment utiliser DeleteTable.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>
/// Delete a table from an AWS Glue database.
/// </summary>
/// <param name="tableName">The table to delete.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> DeleteTableAsync(string dbName, string tableName)
{
    var response = await _amazonGlue.DeleteTableAsync(new DeleteTableRequest
    { Name = tableName, DatabaseName = dbName });
    return response.HttpStatusCode == HttpStatusCode.OK;
}
```

- Pour plus de détails sur l'API, reportez-vous [DeleteTable](#) à la section Référence des AWS SDK pour .NET API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const deleteTable = (databaseName, tableName) => {
    const client = new GlueClient({});
```

```
const command = new DeleteTableCommand({
  DatabaseName: databaseName,
  Name: tableName,
});

return client.send(command);
};
```

- Pour plus de détails sur l'API, reportez-vous [DeleteTable](#) à la section Référence des AWS SDK pour JavaScript API.

PHP

Kit SDK pour PHP

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
echo "Delete the tables.\n";
foreach ($tables['TableList'] as $table) {
    $glueService->deleteTable($table['Name'], $databaseName);
}

public function deleteTable($tableName, $databaseName)
{
    return $this->glueClient->deleteTable([
        'DatabaseName' => $databaseName,
        'Name' => $tableName,
    ]);
}
```

- Pour plus de détails sur l'API, reportez-vous [DeleteTable](#) à la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def delete_table(self, db_name, table_name):
        """
        Deletes a table from a metadata database.

        :param db_name: The name of the database that contains the table.
        :param table_name: The name of the table to delete.
        """
        try:
            self.glue_client.delete_table(DatabaseName=db_name, Name=table_name)
        except ClientError as err:
            logger.error(
                "Couldn't delete table %s. Here's why: %s: %s",
                table_name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
```

- Pour plus de détails sur l'API, consultez [DeleteTable](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Deletes a table with the specified name.
  #
  # @param database_name [String] The name of the catalog database in which the
  # table resides.
  # @param table_name [String] The name of the table to be deleted.
  # @return [void]
  def delete_table(database_name, table_name)
    @glue_client.delete_table(database_name: database_name, name: table_name)
  rescue Aws::Glue::Errors::ServiceError => e
    @logger.error("Glue could not delete job: \n#{e.message}")
  end
end
```

- Pour plus de détails sur l'API, reportez-vous [DeleteTable](#) à la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
for t in &self.tables {
    glue.delete_table()
        .name(t.name())
        .database_name(self.database())
        .send()
        .await
        .map_err(GlueMvpError::from_glue_sdk)?;
}
```

- Pour plus de détails sur l'API, voir [DeleteTable](#) la section de référence de l'API AWS SDK for Rust.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **GetCrawler** avec un AWS SDK

Les exemples de code suivants illustrent comment utiliser `GetCrawler`.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>
/// Get information about an AWS Glue crawler.
/// </summary>
/// <param name="crawlerName">The name of the crawler.</param>
/// <returns>A Crawler object describing the crawler.</returns>
public async Task<Crawler?> GetCrawlerAsync(string crawlerName)
{
    var crawlerRequest = new GetCrawlerRequest
    {
        Name = crawlerName,
    };

    var response = await _amazonGlue.GetCrawlerAsync(crawlerRequest);
    if (response.HttpStatusCode == System.Net.HttpStatusCode.OK)
    {
        var databaseName = response.Crawler.DatabaseName;
        Console.WriteLine($"{crawlerName} has the database {databaseName}");
        return response.Crawler;
    }

    Console.WriteLine($"No information regarding {crawlerName} could be found.");
    return null;
}
```

- Pour plus de détails sur l'API, reportez-vous [GetCrawler](#) à la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

 Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
Aws::Client::ClientConfiguration clientConfig;
// Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
// clientConfig.region = "us-east-1";

Aws::Glue::GlueClient client(clientConfig);

Aws::Glue::Model::GetCrawlerRequest request;
request.SetName(CRAWLER_NAME);

Aws::Glue::Model::GetCrawlerOutcome outcome = client.GetCrawler(request);

if (outcome.IsSuccess()) {
    Aws::Glue::Model::CrawlerState crawlerState =
outcome.GetResult().GetCrawler().GetState();
    std::cout << "Retrieved crawler with state " <<

Aws::Glue::Model::CrawlerStateMapper::GetNameForCrawlerState(
        crawlerState)
    << "." << std::endl;
}
else {
    std::cerr << "Error retrieving a crawler. "
        << outcome.GetError().GetMessage() << std::endl;
    deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
        clientConfig);
    return false;
}
```

- Pour plus de détails sur l'API, reportez-vous [GetCrawler](#) à la section Référence des AWS SDK pour C++ API.

Java

SDK pour Java 2.x

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/**
 * Retrieves a specific crawler from the AWS Glue service and waits for it to
 * be in the "READY" state.
 *
 * @param glueClient the AWS Glue client used to interact with the Glue
 * service
 * @param crawlerName the name of the crawler to be retrieved
 */
public static void getSpecificCrawler(GlueClient glueClient, String
crawlerName) throws InterruptedException {
    try {
        GetCrawlerRequest crawlerRequest = GetCrawlerRequest.builder()
            .name(crawlerName)
            .build();

        boolean ready = false;
        while (!ready) {
            GetCrawlerResponse response =
glueClient.getCrawler(crawlerRequest);
            String status = response.crawler().stateAsString();
            if (status.compareTo("READY") == 0) {
                ready = true;
            }
            Thread.sleep(3000);
        }

        System.out.println("The crawler is now ready");

    } catch (GlueException | InterruptedException e) {
        throw e;
    }
}
```

- Pour plus de détails sur l'API, reportez-vous [GetCrawler](#) à la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const getCrawler = (name) => {  
  const client = new GlueClient({});  
  
  const command = new GetCrawlerCommand({  
    Name: name,  
  });  
  
  return client.send(command);  
};
```

- Pour plus de détails sur l'API, reportez-vous [GetCrawler](#) à la section Référence des AWS SDK pour JavaScript API.

Kotlin

SDK pour Kotlin

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
suspend fun getSpecificCrawler(crawlerName: String?) {
    val request =
        GetCrawlerRequest {
            name = crawlerName
        }
    GlueClient { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.getCrawler(request)
        val role = response.crawler?.role
        println("The role associated with this crawler is $role")
    }
}
```

- Pour plus de détails sur l'API, reportez-vous [GetCrawler](#) à la section AWS SDK pour la référence de l'API Kotlin.

PHP

Kit SDK pour PHP

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
echo "Waiting for crawler";
do {
    $crawler = $glueService->getCrawler($crawlerName);
    echo ".";
    sleep(10);
} while ($crawler['Crawler']['State'] != "READY");
echo "\n";

public function getCrawler($crawlerName)
{
    return $this->customWaiter(function () use ($crawlerName) {
        return $this->glueClient->getCrawler([
            'Name' => $crawlerName,
        ]);
    });
}
```

```
}
```

- Pour plus de détails sur l'API, reportez-vous [GetCrawler](#) à la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def get_crawler(self, name):
        """
        Gets information about a crawler.

        :param name: The name of the crawler to look up.
        :return: Data about the crawler.
        """
        crawler = None
        try:
            response = self.glue_client.get_crawler(Name=name)
            crawler = response["Crawler"]
        except ClientError as err:
            if err.response["Error"]["Code"] == "EntityNotFoundException":
                logger.info("Crawler %s doesn't exist.", name)
            else:
```

```
        logger.error(  
            "Couldn't get crawler %s. Here's why: %s: %s",  
            name,  
            err.response["Error"]["Code"],  
            err.response["Error"]["Message"],  
        )  
        raise  
    return crawler
```

- Pour plus de détails sur l'API, consultez [GetCrawler](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing  
# a simplified interface for common operations.  
# It encapsulates the functionality of the AWS SDK for Glue and provides methods  
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.  
# The class initializes with a Glue client and a logger, allowing it to make API  
# calls and log any errors or informational messages.  
class GlueWrapper  
  def initialize(glue_client, logger)  
    @glue_client = glue_client  
    @logger = logger  
  end  
  
  # Retrieves information about a specific crawler.  
  #  
  # @param name [String] The name of the crawler to retrieve information about.
```

```
# @return [Aws::Glue::Types::Crawler, nil] The crawler object if found, or nil
if not found.
def get_crawler(name)
  @glue_client.get_crawler(name: name)
rescue Aws::Glue::Errors::EntityNotFoundException
  @logger.info("Crawler #{name} doesn't exist.")
  false
rescue Aws::Glue::Errors::GlueException => e
  @logger.error("Glue could not get crawler #{name}: \n#{e.message}")
  raise
end
```

- Pour plus de détails sur l'API, reportez-vous [GetCrawler](#) à la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
let tmp_crawler = glue
  .get_crawler()
  .name(self.crawler())
  .send()
  .await
  .map_err(GlueMvpError::from_glue_sdk)?;
```

- Pour plus de détails sur l'API, voir [GetCrawler](#) la section de référence de l'API AWS SDK for Rust.

Swift

Kit SDK pour Swift

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
import AWSClientRuntime
import AWSGlue

/// Get the state of the specified AWS Glue crawler.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - name: The name of the crawler whose state should be returned.
///
/// - Returns: A `GlueClientTypes.CrawlerState` value describing the
///   state of the crawler.
func getCrawlerState(glueClient: GlueClient, name: String) async ->
GlueClientTypes.CrawlerState {
    do {
        let output = try await glueClient.getCrawler(
            input: GetCrawlerInput(name: name)
        )

        // If the crawler or its state is `nil`, report that the crawler
        // is stopping. This may not be what you want for your
        // application but it works for this one!

        guard let crawler = output.crawler else {
            return GlueClientTypes.CrawlerState.stopping
        }
        guard let state = crawler.state else {
            return GlueClientTypes.CrawlerState.stopping
        }
        return state
    } catch {
        return GlueClientTypes.CrawlerState.stopping
    }
}
```



```
}
```

- Pour plus de détails sur l'API, reportez-vous [GetCrawler](#) à la section AWS SDK pour la référence de l'API Swift.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **GetDatabase** avec un AWS SDK

Les exemples de code suivants illustrent comment utiliser GetDatabase.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>
/// Get information about an AWS Glue database.
/// </summary>
/// <param name="dbName">The name of the database.</param>
/// <returns>A Database object containing information about the database.</
returns>
public async Task<Database> GetDatabaseAsync(string dbName)
{
    var databasesRequest = new GetDatabaseRequest
```

```

    {
        Name = dbName,
    };

    var response = await _amazonGlue.GetDatabaseAsync(databasesRequest);
    return response.Database;
}

```

- Pour plus de détails sur l'API, reportez-vous [GetDatabase](#) à la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

    Aws::Client::ClientConfiguration clientConfig;
    // Optional: Set to the AWS Region in which the bucket was created
    (overrides config file).
    // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

    Aws::Glue::Model::GetDatabaseRequest request;
    request.SetName(CRAWLER_DATABASE_NAME);

    Aws::Glue::Model::GetDatabaseOutcome outcome =
    client.GetDatabase(request);

    if (outcome.IsSuccess()) {
        const Aws::Glue::Model::Database &database =
        outcome.GetResult().GetDatabase();

        std::cout << "Successfully retrieve the database\n" <<

```

```

        database.Jsonize().View().WriteReadable() << "." <<
std::endl;
    }
    else {
        std::cerr << "Error getting the database. "
        << outcome.GetError().GetMessage() << std::endl;
        deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
            clientConfig);
        return false;
    }
}

```

- Pour plus de détails sur l'API, reportez-vous [GetDatabase](#) à la section Référence des AWS SDK pour C++ API.

Java

SDK pour Java 2.x

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

/**
 * Retrieves the specific database from the AWS Glue service.
 *
 * @param glueClient an instance of the AWS Glue client used to interact
with the service
 * @param databaseName the name of the database to retrieve
 * @throws GlueException if there is an error retrieving the database from
the AWS Glue service
 */
public static void getSpecificDatabase(GlueClient glueClient, String
databaseName) {
    try {
        GetDatabaseRequest databasesRequest = GetDatabaseRequest.builder()
            .name(databaseName)
            .build();
    }
}

```

```
        GetDatabaseResponse response =
glueClient.getDatabase(databasesRequest);
        Instant createDate = response.database().createTime();

        // Convert the Instant to readable date.
        DateTimeFormatter formatter =
DateTimeFormatter.ofLocalizedDateTime(FormatStyle.SHORT)
                .withLocale(Locale.US)
                .withZone(ZoneId.systemDefault());

        formatter.format(createDate);
        System.out.println("The create date of the database is " +
createDate);

    } catch (GlueException e) {
        throw e;
    }
}
```

- Pour plus de détails sur l'API, reportez-vous [GetDatabase](#) à la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const getDatabase = (name) => {
    const client = new GlueClient({});

    const command = new GetDatabaseCommand({
        Name: name,
    });

    return client.send(command);
}
```

```
};
```

- Pour plus de détails sur l'API, reportez-vous [GetDatabase](#) à la section Référence des AWS SDK pour JavaScript API.

Kotlin

SDK pour Kotlin

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
suspend fun getSpecificDatabase(databaseName: String?) {  
    val request =  
        GetDatabaseRequest {  
            name = databaseName  
        }  
  
    GlueClient { region = "us-east-1" }.use { glueClient ->  
        val response = glueClient.getDatabase(request)  
        val dbDesc = response.database?.description  
        println("The database description is $dbDesc")  
    }  
}
```

- Pour plus de détails sur l'API, reportez-vous [GetDatabase](#) à la section AWS SDK pour la référence de l'API Kotlin.

PHP

Kit SDK pour PHP

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
$databaseName = "doc-example-database-$uniqid";

$database = $glueService->getDatabase($databaseName);
echo "Found a database named " . $database['Database']['Name'] . "\n";

public function getDatabase(string $databaseName): Result
{
    return $this->customWaiter(function () use ($databaseName) {
        return $this->glueClient->getDatabase([
            'Name' => $databaseName,
        ]);
    });
}
```

- Pour plus de détails sur l'API, reportez-vous [GetDatabase](#) à la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
```

```
def __init__(self, glue_client):
    """
    :param glue_client: A Boto3 Glue client.
    """
    self.glue_client = glue_client

def get_database(self, name):
    """
    Gets information about a database in your Data Catalog.

    :param name: The name of the database to look up.
    :return: Information about the database.
    """
    try:
        response = self.glue_client.get_database(Name=name)
    except ClientError as err:
        logger.error(
            "Couldn't get database %s. Here's why: %s: %s",
            name,
            err.response["Error"]["Code"],
            err.response["Error"]["Message"],
        )
        raise
    else:
        return response["Database"]
```

- Pour plus de détails sur l'API, consultez [GetDatabase](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Retrieves information about a specific database.
  #
  # @param name [String] The name of the database to retrieve information about.
  # @return [Aws::Glue::Types::Database, nil] The database object if found, or
  # nil if not found.
  def get_database(name)
    response = @glue_client.get_database(name: name)
    response.database
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get database #{name}: \n#{e.message}")
    raise
  end
end
```

- Pour plus de détails sur l'API, reportez-vous [GetDatabase](#) à la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
let database = glue
```



```

        .get_database()
        .name(self.database())
        .send()
        .await
        .map_err(GlueMvpError::from_glue_sdk)?
        .to_owned();
    let database = database
        .database()
        .ok_or_else(|| GlueMvpError::Unknown("Could not find
database".into()))?;

```

- Pour plus de détails sur l'API, voir [GetDatabase](#) la section de référence de l'API AWS SDK for Rust.

Swift

Kit SDK pour Swift

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

import AWSClientRuntime
import AWSGlue

/// Get the AWS Glue database with the specified name.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - name: The name of the database to return.
///
/// - Returns: The `GlueClientTypes.Database` object describing the
///   specified database, or `nil` if an error occurs or the database
///   isn't found.
func getDatabase(glueClient: GlueClient, name: String) async ->
GlueClientTypes.Database? {
    do {
        let output = try await glueClient.getDatabase(

```

```
        input: GetDatabaseInput(name: name)
    )

    return output.database
} catch {
    return nil
}
```

- Pour plus de détails sur l'API, reportez-vous [GetDatabase](#) à la section AWS SDK pour la référence de l'API Swift.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **GetDatabases** avec un AWS SDK ou une CLI

Les exemples de code suivants illustrent comment utiliser GetDatabases.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

CLI

AWS CLI

Pour répertorier les définitions de certaines ou de toutes les bases de données du AWS Glue Data Catalog

L'exemple get-databases suivant renvoie des informations sur les bases de données du catalogue de données.

```
aws glue get-databases
```

Sortie :

```
{
  "DatabaseList": [
    {
      "Name": "default",
      "Description": "Default Hive database",
      "LocationUri": "file:/spark-warehouse",
      "CreateTime": 1602084052.0,
      "CreateTableDefaultPermissions": [
        {
          "Principal": {
            "DataLakePrincipalIdentifier": "IAM_ALLOWED_PRINCIPALS"
          },
          "Permissions": [
            "ALL"
          ]
        }
      ],
      "CatalogId": "111122223333"
    },
    {
      "Name": "flights-db",
      "CreateTime": 1587072847.0,
      "CreateTableDefaultPermissions": [
        {
          "Principal": {
            "DataLakePrincipalIdentifier": "IAM_ALLOWED_PRINCIPALS"
          },
          "Permissions": [
            "ALL"
          ]
        }
      ],
      "CatalogId": "111122223333"
    },
    {
      "Name": "legislators",
      "CreateTime": 1601415625.0,
      "CreateTableDefaultPermissions": [
        {
          "Principal": {
            "DataLakePrincipalIdentifier": "IAM_ALLOWED_PRINCIPALS"
          },
          "Permissions": [
```

```

        "ALL"
      ]
    }
  ],
  "CatalogId": "111122223333"
},
{
  "Name": "tempdb",
  "CreateTime": 1601498566.0,
  "CreateTableDefaultPermissions": [
    {
      "Principal": {
        "DataLakePrincipalIdentifier": "IAM_ALLOWED_PRINCIPALS"
      },
      "Permissions": [
        "ALL"
      ]
    }
  ],
  "CatalogId": "111122223333"
}
]
}

```

Pour plus d'informations, consultez [Définition d'une base de données dans votre catalogue de données](#) dans le Guide du développeur AWS Glue.

- Pour plus de détails sur l'API, voir [GetDatabases](#) la section Référence des AWS CLI commandes.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

const getDatabases = () => {
  const client = new GlueClient({});

```

```
const command = new GetDatabasesCommand({});

return client.send(command);
};
```

- Pour plus de détails sur l'API, voir [GetDatabases](#) la section Référence des AWS SDK pour JavaScript API.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **GetJob** avec un AWS SDK ou une CLI

Les exemples de code suivants illustrent comment utiliser GetJob.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

CLI

AWS CLI

Pour récupérer des informations sur une tâche

L'exemple `get-job` suivant récupère des informations sur une tâche.

```
aws glue get-job \
  --job-name my-testing-job
```

Sortie :

```
{
  "Job": {
    "Name": "my-testing-job",
    "Role": "Glue_DefaultRole",
```

```
    "CreatedOn": 1602805698.167,  
    "LastModifiedOn": 1602805698.167,  
    "ExecutionProperty": {  
        "MaxConcurrentRuns": 1  
    },  
    "Command": {  
        "Name": "gluestreaming",  
        "ScriptLocation": "s3://janetst-bucket-01/Scripts/test_script.scala",  
        "PythonVersion": "2"  
    },  
    "DefaultArguments": {  
        "--class": "GlueApp",  
        "--job-language": "scala"  
    },  
    "MaxRetries": 0,  
    "AllocatedCapacity": 10,  
    "MaxCapacity": 10.0,  
    "GlueVersion": "1.0"  
  }  
}
```

Pour plus d'informations, consultez [Tâches](#) dans le Guide du développeur AWS Glue.

- Pour plus de détails sur l'API, reportez-vous [GetJob](#) à la section Référence des AWS CLI commandes.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const getJob = (jobName) => {  
  const client = new GlueClient({});  
  
  const command = new GetJobCommand({  
    JobName: jobName,  
  });
```

```
return client.send(command);  
};
```

- Pour plus de détails sur l'API, reportez-vous [GetJob](#) à la section Référence des AWS SDK pour JavaScript API.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **GetJobRun** avec un AWS SDK ou une CLI

Les exemples de code suivants illustrent comment utiliser GetJobRun.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>  
/// Get information about a specific AWS Glue job run.  
/// </summary>  
/// <param name="jobName">The name of the job.</param>  
/// <param name="jobRunId">The Id of the job run.</param>  
/// <returns>A JobRun object with information about the job run.</returns>  
public async Task<JobRun> GetJobRunAsync(string jobName, string jobRunId)  
{
```

```

        var response = await _amazonGlue.GetJobRunAsync(new GetJobRunRequest
        { JobName = jobName, RunId = jobRunId });
        return response.JobRun;
    }

```

- Pour plus de détails sur l'API, reportez-vous [GetJobRun](#) à la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

    Aws::Client::ClientConfiguration clientConfig;
    // Optional: Set to the AWS Region in which the bucket was created
    (overrides config file).
    // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

    Aws::Glue::Model::GetJobRunRequest jobRunRequest;
    jobRunRequest.SetJobName(jobName);
    jobRunRequest.SetRunId(jobRunID);

    Aws::Glue::Model::GetJobRunOutcome jobRunOutcome = client.GetJobRun(
        jobRunRequest);

    if (jobRunOutcome.IsSuccess()) {
        std::cout << "Displaying the job run JSON description." << std::endl;
        std::cout
            <<
jobRunOutcome.GetResult().GetJobRun().Jsonize().View().WriteReadable()
            << std::endl;
    }

```



```

else {
    std::cerr << "Error get a job run. "
               << jobRunOutcome.GetError().GetMessage()
               << std::endl;
}

```

- Pour plus de détails sur l'API, reportez-vous [GetJobRun](#) à la section Référence des AWS SDK pour C++ API.

CLI

AWS CLI

Pour obtenir des informations sur l'exécution d'une tâche

L'exemple `get-job-run` suivant récupère des informations sur l'exécution d'une tâche.

```

aws glue get-job-run \
  --job-name "Combine legislators data" \
  --run-id jr_012e176506505074d94d761755e5c62538ee1aad6f17d39f527e9140cf0c9a5e

```

Sortie :

```

{
  "JobRun": {
    "Id":
    "jr_012e176506505074d94d761755e5c62538ee1aad6f17d39f527e9140cf0c9a5e",
    "Attempt": 0,
    "JobName": "Combine legislators data",
    "StartedOn": 1602873931.255,
    "LastModifiedOn": 1602874075.985,
    "CompletedOn": 1602874075.985,
    "JobRunState": "SUCCEEDED",
    "Arguments": {
      "--enable-continuous-cloudwatch-log": "true",
      "--enable-metrics": "",
      "--enable-spark-ui": "true",
      "--job-bookmark-option": "job-bookmark-enable",
      "--spark-event-logs-path": "s3://aws-glue-assets-111122223333-us-east-1/sparkHistoryLogs/"
    },

```

```
    "PredecessorRuns": [],
    "AllocatedCapacity": 10,
    "ExecutionTime": 117,
    "Timeout": 2880,
    "MaxCapacity": 10.0,
    "WorkerType": "G.1X",
    "NumberOfWorkers": 10,
    "LogGroupName": "/aws-glue/jobs",
    "GlueVersion": "2.0"
  }
}
```

Pour plus d'informations, consultez [Exécutions de tâches](#) dans le Guide du développeur AWS Glue.

- Pour plus de détails sur l'API, reportez-vous [GetJobRun](#) à la section Référence des AWS CLI commandes.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const getJobRun = (jobName, jobRunId) => {
  const client = new GlueClient({});
  const command = new GetJobRunCommand({
    JobName: jobName,
    RunId: jobRunId,
  });

  return client.send(command);
};
```

- Pour plus de détails sur l'API, reportez-vous [GetJobRun](#) à la section Référence des AWS SDK pour JavaScript API.

PHP

Kit SDK pour PHP

 Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

    $jobName = 'test-job-' . $uniqid;

    $outputBucketUrl = "s3://$bucketName";
    $runId = $glueService->startJobRun($jobName, $databaseName, $tables,
    $outputBucketUrl)['JobRunId'];

    echo "waiting for job";
    do {
        $jobRun = $glueService->getJobRun($jobName, $runId);
        echo ".";
        sleep(10);
    } while (!array_intersect([$jobRun['JobRun']['JobRunState']],
    ['SUCCEEDED', 'STOPPED', 'FAILED', 'TIMEOUT']));
    echo "\n";

    public function getJobRun($jobName, $runId, $predecessorsIncluded = false):
    Result
    {
        return $this->glueClient->getJobRun([
            'JobName' => $jobName,
            'RunId' => $runId,
            'PredecessorsIncluded' => $predecessorsIncluded,
        ]);
    }

```

- Pour plus de détails sur l'API, reportez-vous [GetJobRun](#) à la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def get_job_run(self, name, run_id):
        """
        Gets information about a single job run.

        :param name: The name of the job definition for the run.
        :param run_id: The ID of the run.
        :return: Information about the run.
        """
        try:
            response = self.glue_client.get_job_run(JobName=name, RunId=run_id)
        except ClientError as err:
            logger.error(
                "Couldn't get job run %s/%s. Here's why: %s: %s",
                name,
                run_id,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobRun"]
```

- Pour plus de détails sur l'API, consultez [GetJobRun](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Retrieves data for a specific job run.
  #
  # @param job_name [String] The name of the job run to retrieve data for.
  # @return [Glue::Types::GetJobRunResponse]
  def get_job_run(job_name, run_id)
    @glue_client.get_job_run(job_name: job_name, run_id: run_id)
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get job runs: \n#{e.message}")
  end
end
```

- Pour plus de détails sur l'API, reportez-vous [GetJobRun](#) à la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

 Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
let get_job_run = || async {
    Ok:::<JobRun, GlueMvpError>(
        glue.get_job_run()
            .job_name(self.job())
            .run_id(job_run_id.to_string())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?
            .job_run()
            .ok_or_else(|| GlueMvpError::Unknown("Failed to get
job_run".into()))?
            .to_owned(),
    )
};

let mut job_run = get_job_run().await?;
let mut state =
job_run.job_run_state().unwrap_or(&unknown_state).to_owned();

while matches!(
    state,
    JobRunState::Starting | JobRunState::Stopping | JobRunState::Running
) {
    info!(?state, "Waiting for job to finish");
    tokio::time::sleep(self.wait_delay).await;

    job_run = get_job_run().await?;
    state = job_run.job_run_state().unwrap_or(&unknown_state).to_owned();
}
```

- Pour plus de détails sur l'API, voir [GetJobRun](#) la section de référence de l'API AWS SDK for Rust.

Swift

Kit SDK pour Swift

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
import AWSClientRuntime
import AWSGlue

/// Get information about a specific AWS Glue job run.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - jobName: The name of the job to return job run data for.
///   - id: The run ID of the specific job run to return.
///
/// - Returns: A `GlueClientTypes.JobRun` object describing the state of
///   the job run, or `nil` if an error occurs.
func getJobRun(glueClient: GlueClient, name jobName: String, id: String)
async -> GlueClientTypes.JobRun? {
    do {
        let output = try await glueClient.getJobRun(
            input: GetJobRunInput(
                jobName: jobName,
                runId: id
            )
        )

        return output.jobRun
    } catch {
        return nil
    }
}
```

- Pour plus de détails sur l'API, reportez-vous [GetJobRun](#) à la section AWS SDK pour la référence de l'API Swift.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **GetJobRuns** avec un AWS SDK ou une CLI

Les exemples de code suivants illustrent comment utiliser GetJobRuns.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référéntiel d'exemples de code AWS](#).

```
/// <summary>
/// Get information about all AWS Glue runs of a specific job.
/// </summary>
/// <param name="jobName">The name of the job.</param>
/// <returns>A list of JobRun objects.</returns>
public async Task<List<JobRun>> GetJobRunsAsync(string jobName)
{
    var jobRuns = new List<JobRun>();

    var request = new GetJobRunsRequest
    {
        JobName = jobName,
    };
}
```



```
// No need to loop to get all the log groups--the SDK does it for us
behind the scenes
var paginatorForJobRuns =
    _amazonGlue.Paginators.GetJobRuns(request);

await foreach (var response in paginatorForJobRuns.Responses)
{
    response.JobRuns.ForEach(jobRun =>
    {
        jobRuns.Add(jobRun);
    });
}

return jobRuns;
}
```

- Pour plus de détails sur l'API, voir [GetJobRuns](#) la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
Aws::Client::ClientConfiguration clientConfig;
// Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
// clientConfig.region = "us-east-1";

Aws::Glue::GlueClient client(clientConfig);

Aws::Glue::Model::GetJobRunsRequest getJobRunsRequest;
getJobRunsRequest.SetJobName(jobName);
```

```

    Aws::String nextToken; // Used for pagination.
    std::vector<Aws::Glue::Model::JobRun> allJobRuns;
    do {
        if (!nextToken.empty()) {
            getJobRunsRequest.SetNextToken(nextToken);
        }
        Aws::Glue::Model::GetJobRunsOutcome jobRunsOutcome =
client.GetJobRuns(
            getJobRunsRequest);

        if (jobRunsOutcome.IsSuccess()) {
            const std::vector<Aws::Glue::Model::JobRun> &jobRuns =
jobRunsOutcome.GetResult().GetJobRuns();
            allJobRuns.insert(allJobRuns.end(), jobRuns.begin(),
jobRuns.end());

            nextToken = jobRunsOutcome.GetResult().GetNextToken();
        }
        else {
            std::cerr << "Error getting job runs. "
                << jobRunsOutcome.GetError().GetMessage()
                << std::endl;

            break;
        }
    } while (!nextToken.empty());

```

- Pour plus de détails sur l'API, voir [GetJobRuns](#) la section Référence des AWS SDK pour C++ API.

CLI

AWS CLI

Pour obtenir des informations sur toutes les exécutions d'une tâche

L'exemple `get-job-runs` suivant récupère des informations sur toutes les exécutions d'une tâche.

```

aws glue get-job-runs \
    --job-name "my-testing-job"

```

Sortie :

```
{
  "JobRuns": [
    {
      "Id":
"jr_012e176506505074d94d761755e5c62538ee1aad6f17d39f527e9140cf0c9a5e",
      "Attempt": 0,
      "JobName": "my-testing-job",
      "StartedOn": 1602873931.255,
      "LastModifiedOn": 1602874075.985,
      "CompletedOn": 1602874075.985,
      "JobRunState": "SUCCEEDED",
      "Arguments": {
        "--enable-continuous-cloudwatch-log": "true",
        "--enable-metrics": "",
        "--enable-spark-ui": "true",
        "--job-bookmark-option": "job-bookmark-enable",
        "--spark-event-logs-path": "s3://aws-glue-assets-111122223333-us-
east-1/sparkHistoryLogs/"
      },
      "PredecessorRuns": [],
      "AllocatedCapacity": 10,
      "ExecutionTime": 117,
      "Timeout": 2880,
      "MaxCapacity": 10.0,
      "WorkerType": "G.1X",
      "NumberOfWorkers": 10,
      "LogGroupName": "/aws-glue/jobs",
      "GlueVersion": "2.0"
    },
    {
      "Id":
"jr_03cc19ddab11c4e244d3f735567de74ff93b0b3ef468a713ffe73e53d1aec08f_attempt_2",
      "Attempt": 2,
      "PreviousRunId":
"jr_03cc19ddab11c4e244d3f735567de74ff93b0b3ef468a713ffe73e53d1aec08f_attempt_1",
      "JobName": "my-testing-job",
      "StartedOn": 1602811168.496,
      "LastModifiedOn": 1602811282.39,
      "CompletedOn": 1602811282.39,
      "JobRunState": "FAILED",
      "ErrorMessage": "An error occurred while calling
o122.pyWriteDynamicFrame."
    }
  ]
}
```

```

        Access Denied (Service: Amazon S3; Status Code: 403; Error Code:
AccessDenied;
        Request ID: 021AAB703DB20A2D;
        S3 Extended Request ID: teZk24Y09TkXzBvMPG502L5VJBhe9DJuWA9/
TXtuG0qfByajkfL/Tlqt5JBGdEGpigAqzdMDM/U=)",
        "PredecessorRuns": [],
        "AllocatedCapacity": 10,
        "ExecutionTime": 110,
        "Timeout": 2880,
        "MaxCapacity": 10.0,
        "WorkerType": "G.1X",
        "NumberOfWorkers": 10,
        "LogGroupName": "/aws-glue/jobs",
        "GlueVersion": "2.0"
    },
    {
        "Id":
"jr_03cc19ddab11c4e244d3f735567de74ff93b0b3ef468a713ffe73e53d1aec08f_attempt_1",
        "Attempt": 1,
        "PreviousRunId":
"jr_03cc19ddab11c4e244d3f735567de74ff93b0b3ef468a713ffe73e53d1aec08f",
        "JobName": "my-testing-job",
        "StartedOn": 1602811020.518,
        "LastModifiedOn": 1602811138.364,
        "CompletedOn": 1602811138.364,
        "JobRunState": "FAILED",
        "ErrorMessage": "An error occurred while calling
o122.pyWriteDynamicFrame.
        Access Denied (Service: Amazon S3; Status Code: 403; Error Code:
AccessDenied;
        Request ID: 2671D37856AE7ABB;
        S3 Extended Request ID: RLJCJw20brV
+PpC6Gp0RahyF2fp9f1B5SSb2bTGPNUSPVizLXR11PN3QZ1db+v1o9qRVktNYbW8=)",
        "PredecessorRuns": [],
        "AllocatedCapacity": 10,
        "ExecutionTime": 113,
        "Timeout": 2880,
        "MaxCapacity": 10.0,
        "WorkerType": "G.1X",
        "NumberOfWorkers": 10,
        "LogGroupName": "/aws-glue/jobs",
        "GlueVersion": "2.0"
    }
]

```

```
}
```

Pour plus d'informations, consultez [Exécutions de tâches](#) dans le Guide du développeur AWS Glue.

- Pour plus de détails sur l'API, reportez-vous [GetJobRuns](#) à la section Référence des AWS CLI commandes.

Java

SDK pour Java 2.x

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/**
 * Retrieves the job runs for a given Glue job and prints the status of the
 * job runs.
 *
 * @param glueClient the Glue client used to make API calls
 * @param jobName    the name of the Glue job to retrieve the job runs for
 */
public static void getJobRuns(GlueClient glueClient, String jobName) {
    try {
        GetJobRunsRequest runsRequest = GetJobRunsRequest.builder()
            .jobName(jobName)
            .maxResults(20)
            .build();

        boolean jobDone = false;
        while (!jobDone) {
            GetJobRunsResponse response = glueClient.getJobRuns(runsRequest);
            List<JobRun> jobRuns = response.jobRuns();
            for (JobRun jobRun : jobRuns) {
                String jobState = jobRun.jobRunState().name();
                if (jobState.compareTo("SUCCEEDED") == 0) {
                    System.out.println(jobName + " has succeeded");
                    jobDone = true;
                }
            }
        }
    }
}
```

```
        } else if (jobState.compareTo("STOPPED") == 0) {
            System.out.println("Job run has stopped");
            jobDone = true;

        } else if (jobState.compareTo("FAILED") == 0) {
            System.out.println("Job run has failed");
            jobDone = true;

        } else if (jobState.compareTo("TIMEOUT") == 0) {
            System.out.println("Job run has timed out");
            jobDone = true;

        } else {
            System.out.println("*** Job run state is " +
jobRun.jobRunState().name());
            System.out.println("Job run Id is " + jobRun.id());
            System.out.println("The Glue version is " +
jobRun.glueVersion());
        }
        TimeUnit.SECONDS.sleep(5);
    }

    } catch (GlueException e) {
        throw e;
    } catch (InterruptedException e) {
        throw new RuntimeException(e);
    }
}
```

- Pour plus de détails sur l'API, voir [GetJobRuns](#) la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const getJobRuns = (jobName) => {  
  const client = new GlueClient({});  
  const command = new GetJobRunsCommand({  
    JobName: jobName,  
  });  
  
  return client.send(command);  
};
```

- Pour plus de détails sur l'API, voir [GetJobRuns](#) la section Référence des AWS SDK pour JavaScript API.

PHP

Kit SDK pour PHP

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
$jobName = 'test-job-' . $uniqid;  
  
$jobRuns = $glueService->getJobRuns($jobName);  
  
public function getJobRuns($jobName, $maxResults = 0, $nextToken = ''):  
Result
```

```
{
    $arguments = ['JobName' => $jobName];
    if ($maxResults) {
        $arguments['MaxResults'] = $maxResults;
    }
    if ($nextToken) {
        $arguments['NextToken'] = $nextToken;
    }
    return $this->glueClient->getJobRuns($arguments);
}
```

- Pour plus de détails sur l'API, voir [GetJobRuns](#) la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def get_job_runs(self, job_name):
        """
        Gets information about runs that have been performed for a specific job
        definition.

        :param job_name: The name of the job definition to look up.
```



```

        :return: The list of job runs.
        """
        try:
            response = self.glue_client.get_job_runs(JobName=job_name)
        except ClientError as err:
            logger.error(
                "Couldn't get job runs for %s. Here's why: %s: %s",
                job_name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobRuns"]

```

- Pour plus de détails sur l'API, consultez [GetJobRuns](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger

```

```
end

# Retrieves a list of job runs for the specified job.
#
# @param job_name [String] The name of the job to retrieve job runs for.
# @return [Array<Aws::Glue::Types::JobRun>]
def get_job_runs(job_name)
  response = @glue_client.get_job_runs(job_name: job_name)
  response.job_runs
rescue Aws::Glue::Errors::GlueException => e
  @logger.error("Glue could not get job runs: \n#{e.message}")
end
```

- Pour plus de détails sur l'API, voir [GetJobRuns](#) la section Référence des AWS SDK pour Ruby API.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **GetTables** avec un AWS SDK ou une CLI

Les exemples de code suivants illustrent comment utiliser `GetTables`.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>
/// Get a list of tables for an AWS Glue database.
/// </summary>
/// <param name="dbName">The name of the database.</param>
/// <returns>A list of Table objects.</returns>
public async Task<List<Table>> GetTablesAsync(string dbName)
{
    var request = new GetTablesRequest { DatabaseName = dbName };
    var tables = new List<Table>();

    // Get a paginator for listing the tables.
    var tablePaginator = _amazonGlue.Paginators.GetTables(request);

    await foreach (var response in tablePaginator.Responses)
    {
        tables.AddRange(response.TableList);
    }

    return tables;
}
```

- Pour plus de détails sur l'API, reportez-vous [GetTables](#) à la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
Aws::Client::ClientConfiguration clientConfig;
// Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
// clientConfig.region = "us-east-1";
```

```

    Aws::Glue::GlueClient client(clientConfig);

    Aws::Glue::Model::GetTablesRequest request;
    request.SetDatabaseName(CRAWLER_DATABASE_NAME);
    std::vector<Aws::Glue::Model::Table> all_tables;
    Aws::String nextToken; // Used for pagination.
    do {
        Aws::Glue::Model::GetTablesOutcome outcome =
client.GetTables(request);

        if (outcome.IsSuccess()) {
            const std::vector<Aws::Glue::Model::Table> &tables =
outcome.GetResult().GetTableList();
            all_tables.insert(all_tables.end(), tables.begin(),
tables.end());
            nextToken = outcome.GetResult().GetNextToken();
        }
        else {
            std::cerr << "Error getting the tables. "
                << outcome.GetError().GetMessage()
                << std::endl;
            deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
clientConfig);
            return false;
        }
    } while (!nextToken.empty());

    std::cout << "The database contains " << all_tables.size()
        << (all_tables.size() == 1 ?
            " table." : " tables.") << std::endl;
    std::cout << "Here is a list of the tables in the database.";
    for (size_t index = 0; index < all_tables.size(); ++index) {
        std::cout << "    " << index + 1 << ": " <<
all_tables[index].GetName()
            << std::endl;
    }

    if (!all_tables.empty()) {
        int tableIndex = askQuestionForIntRange(
            "Enter an index to display the database detail ",
            1, static_cast<int>(all_tables.size()));
        std::cout << all_tables[tableIndex -
1].Jsonize().View().WriteReadable()
            << std::endl;
    }

```

```
        tableName = all_tables[tableIndex - 1].GetName();  
    }
```

- Pour plus de détails sur l'API, reportez-vous [GetTables](#) à la section Référence des AWS SDK pour C++ API.

CLI

AWS CLI

Pour répertorier les définitions de tout ou partie des tables dans la base de données spécifiée

L'exemple `get-tables` suivant renvoie des informations sur les tables de la base de données spécifiée.

```
aws glue get-tables --database-name 'tempdb'
```

Sortie :

```
{  
  "TableList": [  
    {  
      "Name": "my-s3-sink",  
      "DatabaseName": "tempdb",  
      "CreateTime": 1602730539.0,  
      "UpdateTime": 1602730539.0,  
      "Retention": 0,  
      "StorageDescriptor": {  
        "Columns": [  
          {  
            "Name": "sensorid",  
            "Type": "int"  
          },  
          {  
            "Name": "currenttemperature",  
            "Type": "int"  
          },  
          {  
            "Name": "status",  
            "Type": "string"  
          }  
        ]  
      }  
    }  
  ]  
}
```

```

        }
    ],
    "Location": "s3://janetst-bucket-01/test-s3-output/",
    "Compressed": false,
    "NumberOfBuckets": 0,
    "SerdeInfo": {
        "SerializationLibrary": "org.openx.data.jsonserde.JsonSerDe"
    },
    "SortColumns": [],
    "StoredAsSubDirectories": false
},
"Parameters": {
    "classification": "json"
},
"CreatedBy": "arn:aws:iam::007436865787:user/JRSTERN",
"IsRegisteredWithLakeFormation": false,
"CatalogId": "007436865787"
},
{
    "Name": "s3-source",
    "DatabaseName": "tempdb",
    "CreateTime": 1602730658.0,
    "UpdateTime": 1602730658.0,
    "Retention": 0,
    "StorageDescriptor": {
        "Columns": [
            {
                "Name": "sensorid",
                "Type": "int"
            },
            {
                "Name": "currenttemperature",
                "Type": "int"
            },
            {
                "Name": "status",
                "Type": "string"
            }
        ]
    },
    "Location": "s3://janetst-bucket-01/",
    "Compressed": false,
    "NumberOfBuckets": 0,
    "SortColumns": [],
    "StoredAsSubDirectories": false
}

```

```

    },
    "Parameters": {
        "classification": "json"
    },
    "CreatedBy": "arn:aws:iam::007436865787:user/JRSTERN",
    "IsRegisteredWithLakeFormation": false,
    "CatalogId": "007436865787"
},
{
    "Name": "test-kinesis-input",
    "DatabaseName": "tempdb",
    "CreateTime": 1601507001.0,
    "UpdateTime": 1601507001.0,
    "Retention": 0,
    "StorageDescriptor": {
        "Columns": [
            {
                "Name": "sensorid",
                "Type": "int"
            },
            {
                "Name": "currenttemperature",
                "Type": "int"
            },
            {
                "Name": "status",
                "Type": "string"
            }
        ],
        "Location": "my-testing-stream",
        "Compressed": false,
        "NumberOfBuckets": 0,
        "SerdeInfo": {
            "SerializationLibrary": "org.openx.data.jsonserde.JsonSerDe"
        },
        "SortColumns": [],
        "Parameters": {
            "kinesisUrl": "https://kinesis.us-east-1.amazonaws.com",
            "streamName": "my-testing-stream",
            "typeOfData": "kinesis"
        },
        "StoredAsSubDirectories": false
    },
    "Parameters": {

```

```

        "classification": "json"
    },
    "CreatedBy": "arn:aws:iam::007436865787:user/JRSTERN",
    "IsRegisteredWithLakeFormation": false,
    "CatalogId": "007436865787"
}
]
}

```

Pour plus d'informations, consultez la section [Définition des tables dans le catalogue de données AWS Glue](#) du AWS Glue Developer Guide.

- Pour plus de détails sur l'API, reportez-vous [GetTables](#) à la section Référence des AWS CLI commandes.

Java

SDK pour Java 2.x

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

/**
 * Retrieves the names of the tables in the specified Glue database.
 *
 * @param glueClient the Glue client to use for the operation
 * @param dbName     the name of the Glue database to retrieve the table
names from
 * @return the name of the first table retrieved, or an empty string if no
tables were found
 */
public static String getGlueTables(GlueClient glueClient, String dbName) {
    String myTableName = "";
    try {
        GetTablesRequest tableRequest = GetTablesRequest.builder()
            .databaseName(dbName)
            .build();
    }
}

```



```
GetTablesResponse response = glueClient.getTables(tableRequest);
List<Table> tables = response.getTableList();
if (tables.isEmpty()) {
    System.out.println("No tables were returned");
} else {
    for (Table table : tables) {
        myTableName = table.getName();
        System.out.println("Table name is: " + myTableName);
    }
}

} catch (GlueException e) {
    throw e;
}
return myTableName;
}
```

- Pour plus de détails sur l'API, reportez-vous [GetTables](#) à la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const getTables = (databaseName) => {
    const client = new GlueClient({});

    const command = new GetTablesCommand({
        DatabaseName: databaseName,
    });

    return client.send(command);
};
```

- Pour plus de détails sur l'API, reportez-vous [GetTables](#) à la section Référence des AWS SDK pour JavaScript API.

PHP

Kit SDK pour PHP

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
$databaseName = "doc-example-database-$uniqid";

$tables = $glueService->getTables($databaseName);

public function getTables($databaseName): Result
{
    return $this->glueClient->getTables([
        'DatabaseName' => $databaseName,
    ]);
}
```

- Pour plus de détails sur l'API, reportez-vous [GetTables](#) à la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def get_tables(self, db_name):
        """
        Gets a list of tables in a Data Catalog database.

        :param db_name: The name of the database to query.
        :return: The list of tables in the database.
        """
        try:
            response = self.glue_client.get_tables(DatabaseName=db_name)
        except ClientError as err:
            logger.error(
                "Couldn't get tables %s. Here's why: %s: %s",
                db_name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["TableList"]
```

- Pour plus de détails sur l'API, consultez [GetTables](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Retrieves a list of tables in the specified database.
  #
  # @param db_name [String] The name of the database to retrieve tables from.
  # @return [Array<Aws::Glue::Types::Table>]
  def get_tables(db_name)
    response = @glue_client.get_tables(database_name: db_name)
    response.table_list
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get tables #{db_name}: \n#{e.message}")
    raise
  end
end
```

- Pour plus de détails sur l'API, reportez-vous [GetTables](#) à la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
let tables = glue
    .get_tables()
    .database_name(self.database())
    .send()
    .await
    .map_err(GlueMvpError::from_glue_sdk)?;

let tables = tables.table_list();
```

- Pour plus de détails sur l'API, voir [GetTables](#) la section de référence de l'API AWS SDK for Rust.

Swift

Kit SDK pour Swift

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
import AWSClientRuntime
import AWSGlue

/// Returns a list of the tables in the specified database.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
```

```

/// - databaseName: The name of the database whose tables are to be
///   returned.
///
/// - Returns: An array of `GlueClientTypes.Table` objects, each
///   describing one table in the named database. An empty array indicates
///   that there are either no tables in the database, or an error
///   occurred before any tables could be found.
func getTablesInDatabase(glueClient: GlueClient, databaseName: String) async
-> [GlueClientTypes.Table] {
    var tables: [GlueClientTypes.Table] = []
    var nextToken: String?

    repeat {
        do {
            let output = try await glueClient.getTables(
                input: GetTablesInput(
                    databaseName: databaseName,
                    nextToken: nextToken
                )
            )

            guard let tableList = output.tableList else {
                return tables
            }

            tables = tables + tableList
            nextToken = output.nextToken
        } catch {
            return tables
        }
    } while nextToken != nil

    return tables
}

```

- Pour plus de détails sur l'API, reportez-vous [GetTables](#) à la section AWS SDK pour la référence de l'API Swift.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **ListJobs** avec un AWS SDK

Les exemples de code suivants illustrent comment utiliser `ListJobs`.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>
/// List AWS Glue jobs using a paginator.
/// </summary>
/// <returns>A list of AWS Glue job names.</returns>
public async Task<List<string>> ListJobsAsync()
{
    var jobNames = new List<string>();

    var listJobsPaginator = _amazonGlue.Paginators.ListJobs(new
ListJobsRequest { MaxResults = 10 });
    await foreach (var response in listJobsPaginator.Responses)
    {
        jobNames.AddRange(response.JobNames);
    }

    return jobNames;
}
```

- Pour plus de détails sur l'API, voir [ListJobs](#) la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
Aws::Client::ClientConfiguration clientConfig;
// Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
// clientConfig.region = "us-east-1";

Aws::Glue::GlueClient client(clientConfig);

Aws::Glue::Model::ListJobsRequest listJobsRequest;

Aws::String nextToken;
std::vector<Aws::String> allJobNames;

do {
    if (!nextToken.empty()) {
        listJobsRequest.SetNextToken(nextToken);
    }
    Aws::Glue::Model::ListJobsOutcome listRunsOutcome = client.ListJobs(
        listJobsRequest);

    if (listRunsOutcome.IsSuccess()) {
        const std::vector<Aws::String> &jobNames =
listRunsOutcome.GetResult().GetJobNames();
        allJobNames.insert(allJobNames.end(), jobNames.begin(),
jobNames.end());
        nextToken = listRunsOutcome.GetResult().GetNextToken();
    }
    else {
        std::cerr << "Error listing jobs. "
```



```
        << listRunsOutcome.GetError().GetMessage()  
        << std::endl;  
    }  
} while (!nextToken.empty());
```

- Pour plus de détails sur l'API, voir [ListJobs](#) la section Référence des AWS SDK pour C++ API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const listJobs = () => {  
    const client = new GlueClient({});  
  
    const command = new ListJobsCommand({});  
  
    return client.send(command);  
};
```

- Pour plus de détails sur l'API, voir [ListJobs](#) la section Référence des AWS SDK pour JavaScript API.

PHP

Kit SDK pour PHP

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

    $jobs = $glueService->listJobs();
    echo "Current jobs:\n";
    foreach ($jobs['JobNames'] as $jobsName) {
        echo "{$jobsName}\n";
    }

    public function listJobs($maxResults = null, $nextToken = null, $tags = []):
    Result
    {
        $arguments = [];
        if ($maxResults) {
            $arguments['MaxResults'] = $maxResults;
        }
        if ($nextToken) {
            $arguments['NextToken'] = $nextToken;
        }
        if (!empty($tags)) {
            $arguments['Tags'] = $tags;
        }
        return $this->glueClient->listJobs($arguments);
    }

```

- Pour plus de détails sur l'API, voir [ListJobs](#) la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """

```

```
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def list_jobs(self):
        """
        Lists the names of job definitions in your account.

        :return: The list of job definition names.
        """
        try:
            response = self.glue_client.list_jobs()
        except ClientError as err:
            logger.error(
                "Couldn't list jobs. Here's why: %s: %s",
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobNames"]
```

- Pour plus de détails sur l'API, consultez [ListJobs](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
a simplified interface for common operations.
```

```
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Retrieves a list of jobs in AWS Glue.
  #
  # @return [Aws::Glue::Types::ListJobsResponse]
  def list_jobs
    @glue_client.list_jobs
    rescue Aws::Glue::Errors::GlueException => e
      @logger.error("Glue could not list jobs: \n#{e.message}")
      raise
    end
  end
end
```

- Pour plus de détails sur l'API, voir [ListJobs](#) la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
let mut list_jobs = glue.list_jobs().into_paginator().send();
while let Some(list_jobs_output) = list_jobs.next().await {
  match list_jobs_output {
    Ok(list_jobs) => {
      let names = list_jobs.job_names();
      info!(?names, "Found these jobs")
    }
  }
}
```

```

        Err(err) => return Err(GlueMvpError::from_glue_sdk(err)),
    }
}

```

- Pour plus de détails sur l'API, voir [ListJobs](#) la section de référence de l'API AWS SDK for Rust.

Swift

Kit SDK pour Swift

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

import AWSClientRuntime
import AWSGlue

/// Return a list of the AWS Glue jobs listed on the user's account.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - maxJobs: The maximum number of jobs to return (default: 100).
///
/// - Returns: An array of strings listing the names of all available AWS
///   Glue jobs.
func listJobs(glueClient: GlueClient, maxJobs: Int = 100) async -> [String] {
    var jobList: [String] = []
    var nextToken: String?

    repeat {
        do {
            let output = try await glueClient.listJobs(
                input: ListJobsInput(
                    maxResults: maxJobs,
                    nextToken: nextToken
                )
            )

```

```
        guard let jobs = output.jobNames else {
            return jobList
        }

        jobList = jobList + jobs
        nextToken = output.nextToken
    } catch {
        return jobList
    }
} while (nextToken != nil)

return jobList
}
```

- Pour plus de détails sur l'API, reportez-vous [ListJobs](#) à la section AWS SDK pour la référence de l'API Swift.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **StartCrawler** avec un AWS SDK ou une CLI

Les exemples de code suivants illustrent comment utiliser `StartCrawler`.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>
/// Start an AWS Glue crawler.
/// </summary>
/// <param name="crawlerName">The name of the crawler.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> StartCrawlerAsync(string crawlerName)
{
    var crawlerRequest = new StartCrawlerRequest
    {
        Name = crawlerName,
    };

    var response = await _amazonGlue.StartCrawlerAsync(crawlerRequest);

    return response.HttpStatusCode == System.Net.HttpStatusCode.OK;
}
```

- Pour plus de détails sur l'API, reportez-vous [StartCrawler](#) à la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

    Aws::Client::ClientConfiguration clientConfig;
    // Optional: Set to the AWS Region in which the bucket was created
    (overrides config file).
    // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

    Aws::Glue::Model::StartCrawlerRequest request;
    request.SetName(CRAWLER_NAME);

    Aws::Glue::Model::StartCrawlerOutcome outcome =
    client.StartCrawler(request);

    if (outcome.IsSuccess() || (Aws::Glue::GlueErrors::CRAWLER_RUNNING ==
                                outcome.GetError().GetErrorType())) {
        if (!outcome.IsSuccess()) {
            std::cout << "Crawler was already started." << std::endl;
        }
        else {
            std::cout << "Successfully started crawler." << std::endl;
        }

        std::cout << "This may take a while to run." << std::endl;

        Aws::Glue::Model::CrawlerState crawlerState =
        Aws::Glue::Model::CrawlerState::NOT_SET;
        int iterations = 0;
        while (Aws::Glue::Model::CrawlerState::READY != crawlerState) {
            std::this_thread::sleep_for(std::chrono::seconds(1));
            ++iterations;
            if ((iterations % 10) == 0) { // Log status every 10 seconds.
                std::cout << "Crawler status " <<

        Aws::Glue::Model::CrawlerStateMapper::GetNameForCrawlerState(
            crawlerState)
            << ". After " << iterations
            << " seconds elapsed."
            << std::endl;
            }
        }
        Aws::Glue::Model::GetCrawlerRequest getCrawlerRequest;
        getCrawlerRequest.SetName(CRAWLER_NAME);

```



```

        Aws::Glue::Model::GetCrawlerOutcome getCrawlerOutcome =
client.GetCrawler(
    getCrawlerRequest);

    if (getCrawlerOutcome.IsSuccess()) {
        crawlerState =
getCrawlerOutcome.GetResult().GetCrawler().GetState();
    }
    else {
        std::cerr << "Error getting crawler.  "
        << getCrawlerOutcome.GetError().GetMessage() <<
std::endl;
        break;
    }
}

if (Aws::Glue::Model::CrawlerState::READY == crawlerState) {
    std::cout << "Crawler finished running after " << iterations
    << " seconds."
    << std::endl;
}
}
else {
    std::cerr << "Error starting a crawler.  "
    << outcome.GetError().GetMessage()
    << std::endl;

    deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
        clientConfig);
    return false;
}

```

- Pour plus de détails sur l'API, reportez-vous [StartCrawler](#) à la section Référence des AWS SDK pour C++ API.

CLI

AWS CLI

Pour démarrer un crawler

L'exemple `start-crawler` suivant démarre un crawler.

```
aws glue start-crawler --name my-crawler
```

Sortie :

None

Pour plus d'informations, consultez [Définition des crawlers](#) dans le Guide du développeur AWS Glue.

- Pour plus de détails sur l'API, reportez-vous [StartCrawler](#) à la section Référence des AWS CLI commandes.

Java

SDK pour Java 2.x

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/**
 * Starts a specific AWS Glue crawler.
 *
 * @param glueClient the AWS Glue client to use for the crawler operation
 * @param crawlerName the name of the crawler to start
 * @throws GlueException if there is an error starting the crawler
 */
public static void startSpecificCrawler(GlueClient glueClient, String
crawlerName) {
    try {
        StartCrawlerRequest crawlerRequest = StartCrawlerRequest.builder()
            .name(crawlerName)
            .build();

        glueClient.startCrawler(crawlerRequest);
        System.out.println(crawlerName + " was successfully started!");
    } catch (GlueException e) {
        throw e;
    }
}
```

```
    }  
}
```

- Pour plus de détails sur l'API, reportez-vous [StartCrawler](#) à la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const startCrawler = (name) => {  
  const client = new GlueClient({});  
  
  const command = new StartCrawlerCommand({  
    Name: name,  
  });  
  
  return client.send(command);  
};
```

- Pour plus de détails sur l'API, reportez-vous [StartCrawler](#) à la section Référence des AWS SDK pour JavaScript API.

Kotlin

SDK pour Kotlin

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
suspend fun startSpecificCrawler(crawlerName: String?) {
    val request =
        StartCrawlerRequest {
            name = crawlerName
        }

    GlueClient { region = "us-west-2" }.use { glueClient ->
        glueClient.startCrawler(request)
        println("$crawlerName was successfully started.")
    }
}
```

- Pour plus de détails sur l'API, consultez [StartCrawler](#) la section AWS SDK pour la référence de l'API Kotlin.

PHP

Kit SDK pour PHP

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
$crawlerName = "example-crawler-test-" . $uniqid;

$databaseName = "doc-example-database-$uniqid";

$glueService->startCrawler($crawlerName);

public function startCrawler($crawlerName): Result
{
    return $this->glueClient->startCrawler([
        'Name' => $crawlerName,
    ]);
}
```

- Pour plus de détails sur l'API, reportez-vous [StartCrawler](#) à la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def start_crawler(self, name):
        """
        Starts a crawler. The crawler crawls its configured target and creates
        metadata that describes the data it finds in the target data source.

        :param name: The name of the crawler to start.
        """
        try:
            self.glue_client.start_crawler(Name=name)
        except ClientError as err:
            logger.error(
                "Couldn't start crawler %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
```

- Pour plus de détails sur l'API, consultez [StartCrawler](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Starts a crawler with the specified name.
  #
  # @param name [String] The name of the crawler to start.
  # @return [void]
  def start_crawler(name)
    @glue_client.start_crawler(name: name)
  rescue Aws::Glue::Errors::ServiceError => e
    @logger.error("Glue could not start crawler #{name}: \n#{e.message}")
    raise
  end
end
```

- Pour plus de détails sur l'API, reportez-vous [StartCrawler](#) à la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
let start_crawler =
glue.start_crawler().name(self.crawler()).send().await;

match start_crawler {
    Ok(_) => Ok(()),
    Err(err) => {
        let glue_err: aws_sdk_glue::Error = err.into();
        match glue_err {
            aws_sdk_glue::Error::CrawlerRunningException(_) => Ok(()),
            _ => Err(GlueMvpError::GlueSdk(glue_err)),
        }
    }
}
}??;
```

- Pour plus de détails sur l'API, voir [StartCrawler](#) la section de référence de l'API AWS SDK for Rust.

Swift

Kit SDK pour Swift

Note

Il y en a plus sur GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
import AWSClientRuntime
import AWSGlue

/// Start running an AWS Glue crawler.
///
/// - Parameters:
///   - glueClient: The AWS Glue client to use when starting the crawler.
///   - name: The name of the crawler to start running.
///
/// - Returns: `true` if the crawler is started successfully, otherwise
`false`.
func startCrawler(glueClient: GlueClient, name: String) async -> Bool {
    do {
        _ = try await glueClient.startCrawler(
            input: StartCrawlerInput(name: name)
        )
    } catch {
        print("*** An unexpected error occurred starting the crawler.")
        return false
    }

    return true
}
```

- Pour plus de détails sur l'API, reportez-vous [StartCrawler](#) à la section AWS SDK pour la référence de l'API Swift.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Utilisation **StartJobRun** avec un AWS SDK ou une CLI

Les exemples de code suivants illustrent comment utiliser StartJobRun.

Les exemples d'actions sont des extraits de code de programmes de plus grande envergure et doivent être exécutés en contexte. Vous pouvez voir cette action en contexte dans l'exemple de code suivant :

- [Principes de base](#)

.NET

SDK pour .NET

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/// <summary>
/// Start an AWS Glue job run.
/// </summary>
/// <param name="jobName">The name of the job.</param>
/// <returns>A string representing the job run Id.</returns>
public async Task<string> StartJobRunAsync(
    string jobName,
    string inputDatabase,
    string inputTable,
    string bucketName)
{
    var request = new StartJobRunRequest
    {
        JobName = jobName,
        Arguments = new Dictionary<string, string>
        {
            {"--input_database", inputDatabase},
            {"--input_table", inputTable},
            {"--output_bucket_url", $"s3://{bucketName}/"}
        }
    };

    var response = await _amazonGlue.StartJobRunAsync(request);
    return response.JobRunId;
}
```

- Pour plus de détails sur l'API, reportez-vous [StartJobRun](#) à la section Référence des AWS SDK pour .NET API.

C++

SDK pour C++

 Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
Aws::Client::ClientConfiguration clientConfig;
// Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
// clientConfig.region = "us-east-1";

Aws::Glue::GlueClient client(clientConfig);

Aws::Glue::Model::StartJobRunRequest request;
request.SetJobName(JOB_NAME);

Aws::Map<Aws::String, Aws::String> arguments;
arguments["--input_database"] = CRAWLER_DATABASE_NAME;
arguments["--input_table"] = tableName;
arguments["--output_bucket_url"] = Aws::String("s3://") + bucketName +
"/";
request.SetArguments(arguments);

Aws::Glue::Model::StartJobRunOutcome outcome =
client.StartJobRun(request);

if (outcome.IsSuccess()) {
    std::cout << "Successfully started the job." << std::endl;

    Aws::String jobRunId = outcome.GetResult().GetJobRunId();

    int iterator = 0;
    bool done = false;
    while (!done) {
        ++iterator;
        std::this_thread::sleep_for(std::chrono::seconds(1));
        Aws::Glue::Model::GetJobRunRequest jobRunRequest;
        jobRunRequest.SetJobName(JOB_NAME);
```

```

        jobRunRequest.SetRunId(jobRunId);

        Aws::Glue::Model::GetJobRunOutcome jobRunOutcome =
client.GetJobRun(
        jobRunRequest);

        if (jobRunOutcome.IsSuccess()) {
            const Aws::Glue::Model::JobRun &jobRun =
jobRunOutcome.GetResult().GetJobRun();
            Aws::Glue::Model::JobRunState jobRunState =
jobRun.GetJobRunState();

            if ((jobRunState == Aws::Glue::Model::JobRunState::STOPPED)
||
                (jobRunState == Aws::Glue::Model::JobRunState::FAILED) ||
                (jobRunState == Aws::Glue::Model::JobRunState::TIMEOUT))
{
                std::cerr << "Error running job. "
                    << jobRun.GetErrorMessage()
                    << std::endl;
                deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME,
JOB_NAME,
                    bucketName,
                    clientConfig);
                return false;
            }
            else if (jobRunState ==
                Aws::Glue::Model::JobRunState::SUCCEEDED) {
                std::cout << "Job run succeeded after " << iterator <<
                    " seconds elapsed." << std::endl;
                done = true;
            }
            else if ((iterator % 10) == 0) { // Log status every 10
seconds.
                std::cout << "Job run status " <<

                Aws::Glue::Model::JobRunStateMapper::GetNameForJobRunState(
                    jobRunState) <<
                    ". " << iterator <<
                    " seconds elapsed." << std::endl;
            }
        }
        else {
            std::cerr << "Error retrieving job run state. "

```

```
        << jobRunOutcome.GetError().GetMessage()
        << std::endl;
        deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, JOB_NAME,
                     bucketName, clientConfig);
        return false;
    }
}
else {
    std::cerr << "Error starting a job. " <<
outcome.GetError().GetMessage()
        << std::endl;
    deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, JOB_NAME,
                 bucketName,
                 clientConfig);
    return false;
}
```

- Pour plus de détails sur l'API, reportez-vous [StartJobRun](#) à la section Référence des AWS SDK pour C++ API.

CLI

AWS CLI

Pour commencer l'exécution d'une tâche

L'exemple `start-job-run` suivant démarre une tâche.

```
aws glue start-job-run \
  --job-name my-job
```

Sortie :

```
{
  "JobRunId":
  "jr_22208b1f44eb5376a60569d4b21dd20fcb8621e1a366b4e7b2494af764b82ded"
}
```

Pour plus d'informations, consultez [Création de tâches](#) dans le Guide du développeur AWS Glue.

- Pour plus de détails sur l'API, reportez-vous [StartJobRun](#) à la section Référence des AWS CLI commandes.

Java

SDK pour Java 2.x

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
/**
 * Starts a job run in AWS Glue.
 *
 * @param glueClient    the AWS Glue client to use for the job run
 * @param jobName       the name of the Glue job to run
 * @param inputDatabase the name of the input database
 * @param inputTable    the name of the input table
 * @param outBucket     the URL of the output S3 bucket
 * @throws GlueException if there is an error starting the job run
 */
public static void startJob(GlueClient glueClient, String jobName, String
inputDatabase, String inputTable,
                          String outBucket) {
    try {
        Map<String, String> myMap = new HashMap<>();
        myMap.put("--input_database", inputDatabase);
        myMap.put("--input_table", inputTable);
        myMap.put("--output_bucket_url", outBucket);

        StartJobRunRequest runRequest = StartJobRunRequest.builder()
            .workerType(WorkerType.G_1_X)
            .numberOfWorkers(10)
            .arguments(myMap)
            .jobName(jobName)
            .build();

        StartJobRunResponse response = glueClient.startJobRun(runRequest);
    }
}
```

```
        System.out.println("The request Id of the job is " +
response.responseMetadata().requestId());

    } catch (GlueException e) {
        throw e;
    }
}
```

- Pour plus de détails sur l'API, reportez-vous [StartJobRun](#) à la section Référence des AWS SDK for Java 2.x API.

JavaScript

SDK pour JavaScript (v3)

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
const startJobRun = (jobName, dbName, tableName, bucketName) => {
    const client = new GlueClient({});

    const command = new StartJobRunCommand({
        JobName: jobName,
        Arguments: {
            "--input_database": dbName,
            "--input_table": tableName,
            "--output_bucket_url": `s3://${bucketName}/`,
        },
    });

    return client.send(command);
};
```

- Pour plus de détails sur l'API, reportez-vous [StartJobRun](#) à la section Référence des AWS SDK pour JavaScript API.

PHP

Kit SDK pour PHP

 Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
$jobName = 'test-job-' . $uniqid;

$databaseName = "doc-example-database-$uniqid";

$tables = $glueService->getTables($databaseName);

$outputBucketUrl = "s3://$bucketName";
$runId = $glueService->startJobRun($jobName, $databaseName, $tables,
$outputBucketUrl)['JobRunId'];

public function startJobRun($jobName, $databaseName, $tables,
$outputBucketUrl): Result
{
    return $this->glueClient->startJobRun([
        'JobName' => $jobName,
        'Arguments' => [
            'input_database' => $databaseName,
            'input_table' => $tables['TableList'][0]['Name'],
            'output_bucket_url' => $outputBucketUrl,
            '--input_database' => $databaseName,
            '--input_table' => $tables['TableList'][0]['Name'],
            '--output_bucket_url' => $outputBucketUrl,
        ],
    ]);
}
```

- Pour plus de détails sur l'API, reportez-vous [StartJobRun](#) à la section Référence des AWS SDK pour PHP API.

Python

SDK pour Python (Boto3)

 Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client

    def start_job_run(self, name, input_database, input_table,
output_bucket_name):
        """
        Starts a job run. A job run extracts data from the source, transforms it,
        and loads it to the output bucket.

        :param name: The name of the job definition.
        :param input_database: The name of the metadata database that contains
tables
                                that describe the source data. This is typically
created
                                by a crawler.
        :param input_table: The name of the table in the metadata database that
describes the source data.
        :param output_bucket_name: The S3 bucket where the output is written.
        :return: The ID of the job run.
        """
        try:
            # The custom Arguments that are passed to this function are used by
the
            # Python ETL script to determine the location of input and output
data.
```



```

        response = self.glue_client.start_job_run(
            JobName=name,
            Arguments={
                "--input_database": input_database,
                "--input_table": input_table,
                "--output_bucket_url": f"s3://{output_bucket_name}/",
            },
        )
    except ClientError as err:
        logger.error(
            "Couldn't start job run %s. Here's why: %s: %s",
            name,
            err.response["Error"]["Code"],
            err.response["Error"]["Message"],
        )
        raise
    else:
        return response["JobRunId"]

```

- Pour plus de détails sur l'API, consultez [StartJobRun](#) le AWS manuel de référence de l'API SDK for Python (Boto3).

Ruby

Kit SDK pour Ruby

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
# a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
# for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
# calls and log any errors or informational messages.

```

```
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Starts a job run for the specified job.
  #
  # @param name [String] The name of the job to start the run for.
  # @param input_database [String] The name of the input database for the job.
  # @param input_table [String] The name of the input table for the job.
  # @param output_bucket_name [String] The name of the output S3 bucket for the
  job.
  # @return [String] The ID of the started job run.
  def start_job_run(name, input_database, input_table, output_bucket_name)
    response = @glue_client.start_job_run(
      job_name: name,
      arguments: {
        '--input_database': input_database,
        '--input_table': input_table,
        '--output_bucket_url': "s3://#{output_bucket_name}/"
      }
    )
    response.job_run_id
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not start job run #{name}: \n#{e.message}")
    raise
  end
end
```

- Pour plus de détails sur l'API, reportez-vous [StartJobRun](#) à la section Référence des AWS SDK pour Ruby API.

Rust

SDK pour Rust

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

let job_run_output = glue
    .start_job_run()
    .job_name(self.job())
    .arguments("--input_database", self.database())
    .arguments(
        "--input_table",
        self.tables
            .first()
            .ok_or_else(|| GlueMvpError::Unknown("Missing crawler
table".into()))?
            .name(),
    )
    .arguments("--output_bucket_url", self.bucket())
    .send()
    .await
    .map_err(GlueMvpError::from_glue_sdk)?;

let job = job_run_output
    .job_run_id()
    .ok_or_else(|| GlueMvpError::Unknown("Missing run id from just
started job".into()))?
    .to_string();

```

- Pour plus de détails sur l'API, voir [StartJobRun](#) la section de référence de l'API AWS SDK for Rust.

Swift

Kit SDK pour Swift

Note

Il y en a plus à ce sujet GitHub. Trouvez l'exemple complet et découvrez comment le configurer et l'exécuter dans le [référentiel d'exemples de code AWS](#).

```

import AWSClientRuntime
import AWSGlue

/// Start an AWS Glue job run.

```

```

///
/// - Parameters:
///   - glueClient: The AWS Glue client to use.
///   - jobName: The name of the job to run.
///   - databaseName: The name of the AWS Glue database to run the job
against.
///   - tableName: The name of the table in the database to run the job
against.
///   - outputURL: The AWS S3 URI of the bucket location into which to
///     write the resulting output.
///
/// - Returns: `true` if the job run is started successfully, otherwise
`false`.
func startJobRun(glueClient: GlueClient, name jobName: String, databaseName:
String,
                 tableName: String, outputURL: String) async -> String? {
    do {
        let output = try await glueClient.startJobRun(
            input: StartJobRunInput(
                arguments: [
                    "--input_database": databaseName,
                    "--input_table": tableName,
                    "--output_bucket_url": outputURL
                ],
                jobName: jobName,
                numberOfWorkers: 10,
                workerType: .g1x
            )
        )

        guard let id = output.jobRunId else {
            return nil
        }

        return id
    } catch {
        return nil
    }
}

```

- Pour plus de détails sur l'API, reportez-vous [StartJobRun](#) à la section AWS SDK pour la référence de l'API Swift.

Pour obtenir la liste complète des guides de développement du AWS SDK et des exemples de code, consultez [Utilisation de ce service avec un AWS SDK](#). Cette rubrique comprend également des informations sur le démarrage et sur les versions précédentes de SDK.

Sécurité dans AWS Glue

La sécurité du cloud AWS est la priorité absolue. En tant que AWS client, vous bénéficiez d'un centre de données et d'une architecture réseau conçus pour répondre aux exigences des entreprises les plus sensibles en matière de sécurité.

La sécurité est une responsabilité partagée entre vous AWS et vous. Le [modèle de responsabilité partagée](#) décrit cette notion par les termes sécurité du cloud et sécurité dans le cloud :

- **Sécurité du cloud** : AWS est chargée de protéger l'infrastructure qui exécute les AWS services dans le AWS cloud. AWS vous fournit également des services que vous pouvez utiliser en toute sécurité. Des auditeurs tiers testent et vérifient régulièrement l'efficacité de notre sécurité dans le cadre des [programmes de conformité AWS](#). Pour en savoir plus sur les programmes de conformité qui s'appliquent à AWS Glue, consultez la section [AWS Services concernés par programme de conformité](#).
- **Sécurité dans le cloud** — Votre responsabilité est déterminée par le AWS service que vous utilisez. Vous êtes également responsable d'autres facteurs, y compris de la sensibilité de vos données, des exigences de votre entreprise, ainsi que de la législation et de la réglementation applicables.

Cette documentation vous aide à comprendre comment appliquer le modèle de responsabilité partagée lors de l'utilisation de AWS Glue. Les rubriques suivantes expliquent comment configurer AWS Glue pour répondre à vos objectifs de sécurité et de conformité. Vous apprendrez également à utiliser d'autres AWS services qui vous aident à surveiller et à sécuriser vos AWS Glue ressources.

Rubriques

- [Protection des données dans AWS Glue](#)
- [Gestion des identités et des accès pour AWS Glue](#)
- [AWS Lake Formation modèles de contrôle d'accès](#)
- [Utilisation d'Amazon S3 Access Grants avec AWS Glue](#)
- [Connexion et surveillance AWS Glue](#)
- [Validation de conformité pour AWS Glue](#)
- [Résilience dans AWS Glue](#)
- [Sécurité de l'infrastructure dans AWS Glue](#)

Protection des données dans AWS Glue

AWS Glue propose plusieurs fonctionnalités conçues pour protéger vos données.

Rubriques

- [Chiffrement des données au repos](#)
- [chiffrement des données en transit](#)
- [Conformité FIPS](#)
- [Gestion des clés](#)
- [AWS Glue dépendance à l'égard d'autres AWS services](#)
- [Points de terminaison de développement](#)

Chiffrement des données au repos

AWS Glue prend en charge le chiffrement des données au repos pour [Création de tâches ETL visuelles avec AWS Glue Studio](#) et [Développement de scripts à l'aide de points de terminaison de développement](#). Vous pouvez configurer des tâches d'extraction, de transformation et de chargement (ETL) et des points de terminaison de développement pour utiliser des clés [AWS Key Management Service \(AWS KMS\)](#) pour l'écriture de données chiffrées au repos. Vous pouvez également chiffrer les métadonnées stockées dans les clés [AWS Glue Data Catalog](#) d'utilisation que vous utilisez pour gérer AWS KMS. En outre, vous pouvez utiliser des AWS KMS clés pour chiffrer les signets de tâches et les journaux générés par les robots d'[exploration et les](#) tâches ETL.

Vous pouvez chiffrer des objets de métadonnées AWS Glue Data Catalog en plus des données écrites sur Amazon Simple Storage Service (Amazon S3) et CloudWatch Amazon Logs par des jobs, des robots d'exploration et des points de terminaison de développement. Lorsque vous créez des emplois, des robots d'exploration et des points de terminaison de développement dans AWS Glue, vous pouvez fournir des paramètres de chiffrement en joignant une configuration de sécurité. Les configurations de sécurité contiennent des clés de chiffrement côté serveur (SSE-S3) gérées par Amazon S3 ou des clés principales du client (CMKs) stockées dans (SSE-KMSCMKs). AWS KMS Vous pouvez créer des configurations de sécurité à l'aide du AWS Glue console.

Vous pouvez activer le chiffrement de la totalité du catalogue de données dans votre compte. Pour ce faire, spécifiez « CMKs stocké dans AWS KMS ».

 Important

AWS Glue prend uniquement en charge les clés symétriques gérées par le client. Pour plus d'informations, voir [Customer Managed Keys \(CMKs\)](#) dans le Guide du AWS Key Management Service développeur.

Une fois le chiffrement activé, lorsque vous ajoutez des objets du catalogue de données, exécutez des crawlers ou des tâches, ou bien démarrez des points de terminaison de développement, les clés SSE-S3 ou SSE-KMS sont utilisées pour écrire les données au repos. De plus, vous pouvez configurer AWS Glue pour accéder uniquement aux magasins de données Java Database Connectivity (JDBC) via un protocole TLS (Transport Layer Security) fiable.

Entrée AWS Glue, vous pouvez contrôler les paramètres de chiffrement aux emplacements suivants :

- Paramètres de votre catalogue de données.
- Les configurations de sécurité que vous créez.
- Le paramètre de chiffrement côté serveur (SSE-S3 ou SSE-KMS) qui est transmis en tant que paramètre à votre AWS Glue Tâche ETL (extraction, transformation et chargement).

Pour plus d'informations sur la mise en place du chiffrement, consultez [Configuration du chiffrement dans AWS Glue](#).

Rubriques

- [Chiffrement de votre catalogue de données](#)
- [Chiffrement des mots de passe de connexion](#)
- [Chiffrement de données écrites par AWS Glue](#)

Chiffrement de votre catalogue de données

AWS Glue Data Catalog le chiffrement renforce la sécurité de vos données sensibles. AWS Glue s'intègre à AWS Key Management Service (AWS KMS) pour chiffrer les métadonnées stockées dans le catalogue de données. Vous pouvez activer ou désactiver les paramètres de chiffrement pour les ressources du catalogue de données à l'aide de la AWS Glue console ou du AWS CLI.

Lorsque vous activez le chiffrement pour votre catalogue de données, tous les nouveaux objets que vous créez sont chiffrés. Lorsque vous désactivez le chiffrement, les nouveaux objets que vous créez ne sont pas chiffrés, mais les objets chiffrés existants restent chiffrés.

Vous pouvez chiffrer l'intégralité de votre catalogue de données à l'aide de clés de chiffrement AWS gérées ou de clés de chiffrement gérées par le client. Pour plus d'informations sur les types de clés et les états, consultez [AWS Key Management Service les concepts](#) du Guide du AWS Key Management Service développeur.

Note

Lorsque vous utilisez le catalogue de données chiffré avec un robot d'exploration, vous devez conserver les paramètres de chiffrement. La suppression des paramètres de chiffrement après qu'un robot d'exploration a traité un catalogue chiffré entraîne des erreurs. Si vous devez supprimer des paramètres de chiffrement, créez un nouveau robot d'exploration au lieu de modifier celui qui existe déjà.

AWS clés gérées

AWS les clés gérées sont des clés KMS de votre compte qui sont créées, gérées et utilisées en votre nom par un AWS service intégré à AWS KMS. Vous pouvez consulter les clés AWS gérées de votre compte, consulter leurs politiques clés et vérifier leur utilisation dans AWS CloudTrail les journaux. Cependant, vous ne pouvez pas gérer ces clés ni modifier leurs autorisations.

Le chiffrement au repos s'intègre AWS KMS automatiquement AWS à la gestion des clés gérées utilisées pour AWS Glue chiffrer vos métadonnées. Si aucune clé AWS gérée n'existe lorsque vous activez le chiffrement des métadonnées, une nouvelle clé est AWS KMS automatiquement créée pour vous.

Pour en savoir plus, consultez [Clés gérées par AWS](#).

Clés gérées par le client

Les clés gérées par le client sont des clés KMS Compte AWS que vous créez, détenez et gérez. Vous avez un contrôle total sur ces clés KMS. Vous pouvez :

- Établir et maintenir leurs politiques clés, leurs politiques IAM et leurs subventions
- Activez-les et désactivez-les
- Faites pivoter leur matériel cryptographique

- Ajout de balises
- Créez des alias qui y font référence
- Planifiez-les pour leur suppression

Pour plus d'informations sur la gestion des autorisations associées à une clé gérée par le client, consultez la section [Clés gérées par le client](#).

 Important

AWS Glue prend uniquement en charge les clés symétriques gérées par le client. La liste des clés KMS affiche uniquement les clés symétriques. Toutefois, si vous sélectionnez Choisir un ARN de clé KMS, la console vous permet de saisir un ARN pour n'importe quel type de clé. Assurez-vous de n'entrer que ARNs pour les clés symétriques.

Pour créer une clé symétrique gérée par le client, suivez les étapes de [création de clés symétriques gérées par le client](#) dans le guide du AWS Key Management Service développeur.

Lorsque vous activez le chiffrement du catalogue de données au repos, les types de ressources suivants sont chiffrés à l'aide de clés KMS :

- Bases de données
- Tables
- Partitions
- Versions de table
- Statistiques de colonne
- Fonctions définies par l'utilisateur
- Vues du catalogue de données

AWS Glue contexte de chiffrement

Un [contexte de chiffrement](#) est un ensemble facultatif de paires clé-valeur qui contiennent des informations contextuelles supplémentaires sur les données. AWS KMS utilise le contexte de chiffrement en tant que [données authentifiées supplémentaires](#) pour prendre en charge le [chiffrement authentifié](#). Lorsque vous incluez un contexte de chiffrement dans une demande de chiffrement de données, AWS KMS lie le contexte de chiffrement aux données chiffrées. Pour déchiffrer les

données, vous devez inclure le même contexte de chiffrement dans la demande. AWS Glue utilise le même contexte de chiffrement dans toutes les opérations AWS KMS cryptographiques, où la clé est `glue_catalog_id` et la valeur est `lecatalogId`.

```
"encryptionContext": {  
  "glue_catalog_id": "111122223333"  
}
```

Lorsque vous utilisez une clé AWS gérée ou une clé symétrique gérée par le client pour chiffrer votre catalogue de données, vous pouvez également utiliser le contexte de chiffrement dans les enregistrements d'audit et les journaux pour identifier la manière dont la clé est utilisée. Le contexte de chiffrement apparaît également dans les journaux générés par AWS CloudTrail ou dans Amazon CloudWatch les journaux.

Activation du chiffrement

Vous pouvez activer le chiffrement de vos AWS Glue Data Catalog objets dans les paramètres du catalogue de données de la AWS Glue console ou en utilisant le AWS CLI.

Console

Pour activer le chiffrement à l'aide de la console

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez Data Catalog dans le volet de navigation.
3. Sur la page des paramètres du catalogue de données, cochez la case Chiffrement des métadonnées et choisissez une AWS KMS clé.

Lorsque vous activez le chiffrement, si vous ne spécifiez pas de clé gérée par le client, les paramètres de chiffrement utilisent une clé KMS AWS gérée.

4. (Facultatif) Lorsque vous utilisez une clé gérée par le client pour chiffrer votre catalogue de données, celui-ci propose une option permettant d'enregistrer un rôle IAM pour chiffrer et déchiffrer les ressources. Vous devez accorder à votre rôle IAM des autorisations qui AWS Glue peuvent être assumées en votre nom. Cela inclut AWS KMS les autorisations de chiffrement et de déchiffrement des données.

Lorsque vous créez une nouvelle ressource dans le catalogue de données, elle AWS Glue assume le rôle IAM fourni pour chiffrer les données. De même, lorsqu'un consommateur

accède à la ressource, il AWS Glue assume le rôle IAM pour déchiffrer les données. Si vous enregistrez un rôle IAM avec les autorisations requises, le principal appelant n'a plus besoin d'autorisations pour accéder à la clé et déchiffrer les données.

 Important

Vous pouvez déléguer les opérations KMS à un rôle IAM uniquement lorsque vous utilisez une clé gérée par le client pour chiffrer les ressources du catalogue de données. La fonctionnalité de délégation de rôles KMS ne prend pas en charge l'utilisation de clés AWS gérées pour chiffrer les ressources du catalogue de données pour le moment.

 Warning

Lorsque vous activez un rôle IAM pour déléguer les opérations KMS, vous ne pouvez plus accéder aux ressources du catalogue de données précédemment chiffrées à l'aide d'une clé AWS gérée.

- a. Pour activer un rôle IAM AWS Glue capable de chiffrer et de déchiffrer les données en votre nom, sélectionnez l'option Déléguer les opérations KMS à un rôle IAM.
- b. Choisissez ensuite un rôle IAM.

Pour créer un rôle IAM, consultez [Création d'un rôle IAM pour AWS Glue](#).

Le rôle IAM censé accéder AWS Glue au catalogue de données doit disposer des autorisations nécessaires pour chiffrer et déchiffrer les métadonnées du catalogue de données. Vous pouvez créer un rôle IAM et y associer les politiques intégrées suivantes :

- Ajoutez la politique suivante pour inclure AWS KMS les autorisations permettant de chiffrer et de déchiffrer le catalogue de données.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
```

```

        "kms:Decrypt",
        "kms:Encrypt",
        "kms:GenerateDataKey"
    ],
    "Resource": "arn:aws:kms:<region>:<account-id>:key/<key-id>"
  }
]
}

```

- Ajoutez ensuite la politique de confiance suivante au rôle pour que le AWS Glue service assume le rôle IAM.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "",
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}

```

- Ajoutez ensuite l'iam:PassRole autorisation au rôle IAM.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "iam:PassRole"
      ],
      "Resource": [
        "arn:aws:iam::<account-id>:role/<encryption-role-name>"
      ]
    }
  ]
}

```

```
}
```

Lorsque vous activez le chiffrement, si vous n'avez pas spécifié de rôle IAM AWS Glue à assumer, le principal accédant au catalogue de données doit être autorisé à effectuer les opérations d'API suivantes :

- kms:Decrypt
- kms:Encrypt
- kms:GenerateDataKey

AWS CLI

Pour activer le chiffrement à l'aide du SDK ou AWS CLI

- Utilisez l'opération d'API PutDataCatalogEncryptionSettings. Si aucune clé n'est spécifiée, AWS Glue utilise une clé de chiffrement AWS gérée pour le compte client afin de chiffrer le catalogue de données.

```
aws glue put-data-catalog-encryption-settings \  
  --data-catalog-encryption-settings '{  
    "EncryptionAtRest": {  
      "CatalogEncryptionMode": "SSE-KMS-WITH-SERVICE-ROLE",  
      "SseAwsKmsKeyId": "arn:aws:kms:<region>:<account-id>:key/<key-id>",  
      "CatalogEncryptionServiceRole": "arn:aws:iam::<account-  
id>:role/<encryption-role-name>"  
    }  
  }'
```

Lorsque vous activez le chiffrement, tous les objets que vous créez dans les objets du catalogue de données sont chiffrés. Si vous désactivez ce paramètre, les objets que vous créez dans le catalogue de données ne sont plus chiffrés. Vous pouvez continuer à accéder aux objets chiffrés existants dans le catalogue de données avec les autorisations KMS requises.

 Important

La AWS KMS clé doit rester disponible dans le magasin de AWS KMS clés pour tous les objets chiffrés avec elle dans le catalogue de données. Si vous supprimez la clé, les objets ne peuvent plus être déchiffrés. Dans certains scénarios, vous pouvez opter pour cette solution pour empêcher l'accès aux métadonnées du catalogue de données.

Surveillance de vos clés KMS pour AWS Glue

Lorsque vous utilisez des clés KMS avec les ressources de votre catalogue de données, vous pouvez utiliser AWS CloudTrail Amazon CloudWatch nos journaux pour suivre les demandes AWS Glue envoyées à AWS KMS. AWS CloudTrail surveille et enregistre les opérations KMS qui AWS Glue appellent à accéder à des données chiffrées par vos clés KMS.

Les exemples suivants sont AWS CloudTrail des événements relatifs aux GenerateDataKey opérations Decrypt et.

Decrypt

```
{
  "eventVersion": "1.08",
  "userIdentity": {
    "type": "AssumedRole",
    "principalId": "AROAXPHTESTANDEXAMPLE:Sampleuser01",
    "arn": "arn:aws:sts::111122223333:assumed-role/Admin/Sampleuser01",
    "accountId": "111122223333",
    "accessKeyId": "AKIAIOSFODNN7EXAMPLE",
    "sessionContext": {
      "sessionIssuer": {
        "type": "Role",
        "principalId": "AROAXPHTESTANDEXAMPLE",
        "arn": "arn:aws:iam::111122223333:role/Admin",
        "accountId": "111122223333",
        "userName": "Admin"
      },
      "webIdFederationData": {},
      "attributes": {
        "creationDate": "2024-01-10T14:33:56Z",
        "mfaAuthenticated": "false"
      }
    }
  }
}
```

```

    }
  },
  "invokedBy": "glue.amazonaws.com"
},
"eventTime": "2024-01-10T15:18:11Z",
"eventSource": "kms.amazonaws.com",
"eventName": "Decrypt",
"awsRegion": "eu-west-2",
"sourceIPAddress": "glue.amazonaws.com",
"userAgent": "glue.amazonaws.com",
"requestParameters": {
  "encryptionContext": {
    "glue_catalog_id": "111122223333"
  },
  "encryptionAlgorithm": "SYMMETRIC_DEFAULT"
},
"responseElements": null,
"requestID": "43b019aa-34b8-4798-9b98-ee968b2d63df",
"eventID": "d7614763-d3fe-4f84-a1e1-3ca4d2a5bbd5",
"readOnly": true,
"resources": [
  {
    "accountId": "111122223333",
    "type": "AWS::KMS::Key",
    "ARN": "arn:aws:kms:<region>:111122223333:key/<key-id>"
  }
],
"eventType": "AwsApiCall",
"managementEvent": true,
"recipientAccountId": "111122223333",
"eventCategory": "Management",
"sessionCredentialFromConsole": "true"
}

```

GenerateDataKey

```

{
  "eventVersion": "1.08",
  "userIdentity": {
    "type": "AssumedRole",
    "principalId":
      "AROAXPHTESTANDEXAMPLE:V_00_GLUE_KMS_GENERATE_DATA_KEY_111122223333",

```



```

    "arn": "arn:aws:sts::111122223333:assumed-role/Admin/
V_00_GLUE_KMS_GENERATE_DATA_KEY_111122223333",
    "accountId": "111122223333",
    "accessKeyId": "AKIAIOSFODNN7EXAMPLE",
    "sessionContext": {
      "sessionIssuer": {
        "type": "Role",
        "principalId": "AROAXPHTESTANDEXAMPLE",
        "arn": "arn:aws:iam::111122223333:role/Admin",
        "accountId": "AKIAIOSFODNN7EXAMPLE",
        "userName": "Admin"
      },
      "webIdFederationData": {},
      "attributes": {
        "creationDate": "2024-01-05T21:15:47Z",
        "mfaAuthenticated": "false"
      }
    },
    "invokedBy": "glue.amazonaws.com"
  },
  "eventTime": "2024-01-05T21:15:47Z",
  "eventSource": "kms.amazonaws.com",
  "eventName": "GenerateDataKey",
  "awsRegion": "eu-west-2",
  "sourceIPAddress": "glue.amazonaws.com",
  "userAgent": "glue.amazonaws.com",
  "requestParameters": {
    "keyId": "arn:aws:kms:eu-west-2:AKIAIOSFODNN7EXAMPLE:key/
AKIAIOSFODNN7EXAMPLE",
    "encryptionContext": {
      "glue_catalog_id": "111122223333"
    },
    "keySpec": "AES_256"
  },
  "responseElements": null,
  "requestID": "64d1783a-4b62-44ba-b0ab-388b50188070",
  "eventID": "1c73689b-2ef2-443b-aed7-8c126585ca5e",
  "readOnly": true,
  "resources": [
    {
      "accountId": "111122223333",
      "type": "AWS::KMS::Key",
      "ARN": "arn:aws:kms:eu-west-2:111122223333:key/AKIAIOSFODNN7EXAMPLE"
    }
  ]

```

```
],  
  "eventType": "AwsApiCall",  
  "managementEvent": true,  
  "recipientAccountId": "111122223333",  
  "eventCategory": "Management"  
}
```

Chiffrement des mots de passe de connexion

Vous pouvez récupérer les mots de passe de connexion dans AWS Glue Data Catalog le à l'aide des opérations `GetConnections` d'API `GetConnection` et. Ces mots de passe sont stockés dans la connexion au catalogue de données et sont utilisés lorsque AWS Glue se connecte à un magasin de données Java Database Connectivity (JDBC). Lorsque la connexion a été créée ou mise à jour, une option dans les paramètres du catalogue de données déterminait si le mot de passe était crypté et, dans l'affirmative, quelle clé AWS Key Management Service (AWS KMS) était spécifiée.

Sur le AWS Glue console, vous pouvez activer cette option sur la page des paramètres du catalogue de données.

Pour chiffrer des mots de passe de connexion

1. Connectez-vous à la AWS Glue console AWS Management Console et ouvrez-la à l'adresse <https://console.aws.amazon.com/glue/>.
2. Choisissez Settings (Paramètres) dans le volet de navigation.
3. Dans la page Data catalog settings (Paramètres de catalogue de données), sélectionnez Encrypt connection passwords (Chiffrer les mots de passe de connexion) et choisissez une clé AWS KMS .

Important

AWS Glue ne prend en charge que les clés principales symétriques du client (CMKs). La liste de AWS KMS key (clé KMS) n'affiche que des clés symétriques. Toutefois, si

vous sélectionnez Choisir un ARN de AWS KMS clé, la console vous permet de saisir un ARN pour n'importe quel type de clé. Assurez-vous de n'entrer que ARNs pour les clés symétriques.

Pour de plus amples informations, veuillez consulter [Paramètres du catalogue de données](#).

Chiffrement de données écrites par AWS Glue

Une configuration de sécurité est un ensemble de propriétés de sécurité qui peuvent être utilisées par AWS Glue. Vous pouvez utiliser une configuration de sécurité pour chiffrer les données au repos. Les scénarios suivants illustrent les différentes façons dont vous pouvez utiliser une configuration de sécurité.

- Joindre une configuration de sécurité à un AWS Glue robot d'exploration pour écrire des Amazon CloudWatch Logs cryptés. Pour plus d'informations sur l'association de configurations de sécurité aux robots d'exploration, consultez [the section called "Configurer les paramètres de sécurité"](#).
- Associez une configuration de sécurité à une tâche d'extraction, de transformation et de chargement (ETL) pour écrire des cibles Amazon Simple Storage Service (Amazon S3) chiffrées et CloudWatch des journaux chiffrés.
- Attacher une configuration de sécurité à une tâche ETL pour écrire ses signets de tâche sous forme de données Amazon S3 chiffrées.
- Attacher une configuration de sécurité à un point de terminaison de développement pour écrire des cibles Amazon S3 chiffrées.

Important

Actuellement, une configuration de sécurité remplace tout paramètre de chiffrement côté serveur (SSE-S3) qui est transmis en tant que paramètre de tâche ETL. Par conséquent, si une configuration de sécurité et un paramètre SSE-S3 sont associés à une tâche, le paramètre SSE-S3 est ignoré.

Pour plus d'informations sur les configurations de sécurité, consultez [Gestion des configurations de sécurité sur le AWS Glue console](#).

Rubriques

- [Configuration AWS Glue pour utiliser des configurations de sécurité](#)
- [Création d'un itinéraire AWS KMS pour les tâches VPC et les robots d'exploration](#)
- [Gestion des configurations de sécurité sur le AWS Glue console](#)

Configuration AWS Glue pour utiliser des configurations de sécurité

Suivez ces étapes pour configurer votre AWS Glue environnement pour utiliser les configurations de sécurité.

1. Créez ou mettez à jour vos clés AWS Key Management Service (AWS KMS) pour accorder AWS KMS des autorisations aux rôles IAM transmis à AWS Glue robots d'exploration et tâches pour chiffrer les journaux. CloudWatch Pour plus d'informations, consultez la section [Chiffrer les données de journal dans CloudWatch les journaux à l'aide AWS KMS](#) du guide de l'utilisateur Amazon CloudWatch Logs.

Dans l'exemple suivant, *"role1"*, *"role2"*, et *"role3"* sont des rôles IAM transmis aux robots d'exploration et aux tâches.

```
{
  "Effect": "Allow",
  "Principal": { "Service": "logs.region.amazonaws.com",
  "AWS": [
    "role1",
    "role2",
    "role3"
  ] },
  "Action": [
    "kms:Encrypt*",
    "kms:Decrypt*",
    "kms:ReEncrypt*",
    "kms:GenerateDataKey*",
    "kms:Describe*"
  ],
  "Resource": "*"
}
```

L'`Serviceinstruction`, représentée sous la forme `"Service"` :

`"logs.region.amazonaws.com"`, est obligatoire si vous utilisez la clé pour chiffrer CloudWatch les journaux.

2. Assurez-vous que la AWS KMS clé est bien ENABLED là avant de l'utiliser.

Note

Si vous utilisez Iceberg comme cadre de lac de données, les tables Iceberg disposent de leurs propres mécanismes pour activer le chiffrement côté serveur. Vous devez activer ces configurations en plus des configurations AWS Glue de sécurité. Pour activer le chiffrement côté serveur sur les tables Iceberg, consultez les conseils de la [documentation d'Iceberg](#).

Création d'un itinéraire AWS KMS pour les tâches VPC et les robots d'exploration

Vous pouvez vous connecter directement à AWS KMS via un point de terminaison privé dans votre VPC au lieu de vous connecter via Internet. Lorsque vous utilisez un point de terminaison VPC, la communication entre votre VPC et celui-ci AWS KMS s'effectue entièrement au sein du réseau. AWS

Vous pouvez créer un point de terminaison AWS KMS VPC au sein d'un VPC. Sans cette étape, vos tâches ou crawlers peuvent échouer avec un `kms timeout` sur les tâches ou une `internal service exception` sur les crawlers. Pour obtenir des instructions détaillées, consultez la section [Connexion AWS KMS via un point de terminaison VPC](#) dans le guide du AWS Key Management Service développeur.

Au fur et à mesure que vous suivez ces instructions, sur la [console VPC](#), vous devez effectuer les opérations suivantes :

- Sélectionnez `Enable Private DNS name` (Activer le nom DNS privé).
- Choisissez le groupe de sécurité (avec une règle à référence circulaire) que vous utilisez pour votre tâche ou votre crawler qui accède à Java Database Connectivity (JDBC). Pour plus d'informations sur AWS Glue connexions, voir [Connexion aux données](#).

Lorsque vous ajoutez une configuration de sécurité à un robot ou à une tâche qui accède aux magasins de données JDBC, AWS Glue doit avoir un itinéraire vers le AWS KMS point de terminaison. Vous pouvez fournir l'itinéraire à l'aide d'une passerelle de traduction d'adresses

réseau (NAT) ou d'un point de AWS KMS terminaison VPC. Pour créer une passerelle NAT, veuillez consulter [Passerelles NAT](#) dans le Guide de l'utilisateur Amazon VPC.

Gestion des configurations de sécurité sur le AWS Glue console

Warning

AWS Glue les configurations de sécurité ne sont actuellement pas prises en charge dans les tâches Ray.

Une configuration de sécurité dans AWS Glue contient les propriétés nécessaires pour écrire des données chiffrées. Vous créez des configurations de sécurité sur le AWS Glue console pour fournir les propriétés de chiffrement utilisées par les robots d'exploration, les jobs et les points de terminaison de développement.

Pour consulter la liste de toutes les configurations de sécurité que vous avez créées, ouvrez le AWS Glue console sur <https://console.aws.amazon.com/glue/> et choisissez Configurations de sécurité dans le volet de navigation.

La liste Configurations de sécurité affiche les propriétés suivantes pour chaque configuration :

Nom

Nom unique fourni lors de la création de la configuration. Le nom peut contenir des lettres (A à Z), des chiffres (0 à 9), des tirets (-) ou des traits de soulignement (_) et jusqu'à 255 caractères.

Activer le chiffrement Amazon S3

Si cette option est activée, le mode de chiffrement Amazon Simple Storage Service (Amazon S3) tel que SSE-KMS ou SSE-S3 est activé pour le magasin de métadonnées du catalogue de données.

Activer le chiffrement CloudWatch des journaux Amazon

S'il est activé, le mode de chiffrement Amazon S3, tel qu'SSE-KMS est activé lors de l'écriture de journaux sur Amazon CloudWatch.

Paramètres avancés : activer le chiffrement des signets de tâches

Si cette option est activée, le mode de chiffrement Amazon S3 tel que CSE-KMS est activé lorsque les tâches sont marquées d'un signet.

Vous pouvez ajouter ou supprimer des configurations dans la section Configurations de sécurité sur la console. Pour afficher plus de détails sur une configuration, choisissez son nom dans la liste. Les détails incluent les informations que vous avez définies lors de la création de la configuration.

Ajout d'une configuration de sécurité

Pour ajouter une configuration de sécurité à l'aide du AWS Glue console, sur la page Configurations de sécurité, choisissez Ajouter une configuration de sécurité.

Add security configuration

Choose encryption and permission options for your accounts data catalog.

Security configuration properties

Name

Name may contain letters (A-Z), numbers (0-9), hyphens (-), or underscores (_), and can be up to 255 characters long.

Encryption settings

Enable and choose options for at-rest encryption.

☐ Enable S3 encryption
Enable at-rest encryption for metadata stored in the data catalog.

☐ Enable CloudWatch logs encryption
Enable at-rest encryption when writing logs to Amazon CloudWatch.

▼ Advanced settings

☐ Enable job bookmark encryption
Enable at-rest encryption of job bookmark.

Cancel

Save

Propriétés de configuration de sécurité

Saisissez un nom de configuration de sécurité unique. Le nom peut contenir des lettres (A à Z), des chiffres (0 à 9), des tirets (-) ou des traits de soulignement (_) et jusqu'à 255 caractères.

Paramètres de chiffrement

Vous pouvez activer le chiffrement au repos pour les métadonnées stockées dans le catalogue de données d'Amazon S3 et les journaux d'Amazon CloudWatch. Pour configurer le chiffrement des données et des métadonnées à l'aide des clés AWS Key Management Service (AWS KMS) du AWS Glue console, ajoutez une politique à l'utilisateur de la console. Cette politique doit spécifier les ressources autorisées sous forme de noms de ressources Amazon clés (ARNs) utilisés pour chiffrer les magasins de données Amazon S3, comme dans l'exemple suivant.

```
{
  "Version": "2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "kms:GenerateDataKey",
      "kms:Decrypt",
      "kms:Encrypt"],
    "Resource": "arn:aws:kms:region:account-id:key/key-id"
  }
}
```

Important

Lorsqu'une configuration de sécurité est attachée à un robot ou à une tâche, le rôle IAM transmis doit disposer AWS KMS d'autorisations. Pour de plus amples informations, veuillez consulter [Chiffrement de données écrites par AWS Glue](#).

Lorsque vous définissez une configuration, vous pouvez fournir les valeurs des propriétés suivantes :

Activer le chiffrement S3

Lorsque vous écrivez des données Amazon S3, vous utilisez soit le chiffrement côté serveur avec des clés gérées par Amazon S3 (SSE-S3), soit le chiffrement côté serveur avec AWS KMS des clés gérées (SSE-KMS). Ce champ est facultatif. Pour autoriser l'accès à Amazon S3, choisissez une AWS KMS clé ou choisissez Enter a key ARN et fournissez l'ARN de la clé. Entrez l'ARN sous la forme `arn:aws:kms:region:account-id:key/key-id`. Vous pouvez également fournir l'ARN sous la forme d'un alias de clé, (par exemple,) `arn:aws:kms:region:account-id:alias/alias-name`.

Si vous activez l'interface utilisateur Spark pour votre tâche, le fichier journal de l'interface utilisateur Spark chargé sur Amazon S3 sera appliqué avec le même chiffrement.

 Important

AWS Glue prend uniquement en charge les clés principales symétriques du client (CMKs). La liste de AWS KMS key (clé KMS) n'affiche que des clés symétriques. Toutefois, si vous sélectionnez Choisir un ARN de AWS KMS clé, la console vous permet de saisir un ARN pour n'importe quel type de clé. Assurez-vous de n'entrer que des ARNs pour les clés symétriques.

Activer le chiffrement CloudWatch des journaux

Le chiffrement côté serveur (SSE-KMS) est utilisé pour chiffrer les journaux. CloudWatch Ce champ est facultatif. Pour l'activer, choisissez une AWS KMS clé ou choisissez Enter a key ARN et indiquez l'ARN de la clé. Entrez l'ARN sous la forme `arn:aws:kms:region:account-id:key/key-id`. Vous pouvez également fournir l'ARN sous la forme d'un alias de clé, (par exemple,) `arn:aws:kms:region:account-id:alias/alias-name`.

Paramètres avancés : chiffrement des signets de tâches

Le chiffrement côté client (CSE-KMS) est utilisé pour chiffrer les signets de tâche. Ce champ est facultatif. Les données de signet sont chiffrées avant d'être envoyées à Amazon S3 en vue de leur stockage. Pour l'activer, choisissez une AWS KMS clé ou choisissez Enter a key ARN et indiquez l'ARN de la clé. Entrez l'ARN sous la forme `arn:aws:kms:region:account-id:key/key-id`. Vous pouvez également fournir l'ARN sous la forme d'un alias de clé, (par exemple,) `arn:aws:kms:region:account-id:alias/alias-name`.

Pour en savoir plus, consultez les rubriques suivantes dans le Guide de l'utilisateur d'Amazon Simple Storage Service :

- Pour en savoir plus sur SSE-S3, consultez [Protecting Data Using Server-Side Encryption with Amazon S3-Managed Encryption Keys \(SSE-S3\)](#) (Protection des données à l'aide du chiffrement côté serveur avec les clés de chiffrement gérées par Amazon S3 (SSE-S3)).
- Pour plus d'informations SSE-KMS, voir [Protection des données à l'aide du chiffrement côté serveur avec AWS KMS keys](#)
- Pour plus d'informations sur CSE-KMS, veuillez consulter [Using a KMS key stored in AWS KMS](#).

chiffrement des données en transit

AWS fournit un chiffrement TLS (Transport Layer Security) pour les données en mouvement. Vous pouvez configurer les paramètres de chiffrement pour les robots d'exploration, les tâches ETL et les points de terminaison de développement à l'aide des configurations [de sécurité](#) dans AWS Glue. Vous pouvez activer le AWS Glue Data Catalog chiffrement via les paramètres du catalogue de données.

À compter du 4 septembre 2018 AWS KMS (apportez votre propre clé et un chiffrement côté serveur) pour AWS Glue ETL et le AWS Glue Data Catalog sont pris en charge.

Conformité FIPS

Si vous avez besoin de modules cryptographiques validés par la norme FIPS 140-2 pour accéder AWS via une interface de ligne de commande ou une API, utilisez un point de terminaison FIPS. Pour plus d'informations sur les points de terminaison FIPS (Federal Information Processing Standard) disponibles, consultez [Federal Information Processing Standard \(FIPS\) 140-2](#) (Normes de traitement de l'information fédérale).

Gestion des clés

Vous pouvez utiliser AWS Identity and Access Management (IAM) avec AWS Glue pour définir les utilisateurs, les AWS ressources, les groupes, les rôles et les politiques précises concernant l'accès, le refus, etc.

Vous pouvez définir l'accès aux métadonnées en utilisant à la fois les stratégies basées sur les ressources et les stratégies basées sur les identités, en fonction des besoins de votre organisation. Les stratégies basées sur les ressources répertorient les principaux dont l'accès à vos ressources est autorisé ou refusé, ce qui vous permet de configurer des stratégies comme un accès entre comptes. Les stratégies d'identité sont spécifiquement associées à des utilisateurs, des groupes et des rôles au sein d'IAM.

step-by-stepPar exemple, consultez [Restreindre l'accès à vos AWS Glue Data Catalog autorisations IAM au niveau des ressources et à des politiques basées sur les ressources](#) sur le blog Big Data. AWS

La partie relative aux accès affinés de la stratégie est définie dans la clause `Resource`. Cette partie définit à la fois l' AWS Glue Data Catalog objet sur lequel l'action peut être effectuée et les objets résultants renvoyés par cette opération.

Un point de terminaison de développement est un environnement que vous pouvez utiliser pour développer et tester votre AWS Glue scripts. Vous pouvez ajouter ou supprimer la clé SSH d'un point de terminaison de développement, ou en effectuer une rotation.

À compter du 4 septembre 2018 AWS KMS (apportez votre propre clé et un chiffrement côté serveur) pour AWS Glue ETL et le AWS Glue Data Catalog sont pris en charge.

AWS Glue dépendance à l'égard d'autres AWS services

Pour qu'un utilisateur puisse travailler avec AWS Glue console, cet utilisateur doit disposer d'un ensemble minimal d'autorisations lui permettant de travailler avec AWS Glue ressources pour leur AWS compte. En plus de ceux-ci AWS Glue autorisations, la console a besoin des autorisations des services suivants :

- Autorisations Amazon CloudWatch Logs pour afficher les journaux.
- AWS Identity and Access Management Autorisations (IAM) permettant de répertorier et de transmettre des rôles.
- AWS CloudFormation autorisations pour travailler avec des piles.
- Autorisations Amazon Elastic Compute Cloud (Amazon EC2) permettant de répertorier des clouds privés virtuels (VPCs), des sous-réseaux, des groupes de sécurité, des instances et d'autres objets (pour configurer des EC2 éléments Amazon, par exemple VPCs lors de l'exécution de tâches, de robots d'exploration et de la création de points de terminaison de développement).
- Autorisations Amazon Simple Storage Service (Amazon S3) pour répertorier les compartiments et les objets, et pour récupérer et enregistrer les scripts.
- Autorisations Amazon Redshift requises pour travailler avec des clusters.
- Autorisations Amazon Relational Database Service (Amazon RDS) pour répertorier les instances.

Points de terminaison de développement

Un point de terminaison de développement est un environnement que vous pouvez utiliser pour développer et tester votre AWS Glue scripts. Vous pouvez utiliser ... AWS Glue pour créer, modifier et supprimer des points de terminaison de développement. Vous pouvez répertorier tous les points de terminaison de développement créés. Vous pouvez ajouter ou supprimer la clé SSH d'un point de terminaison de développement, ou en effectuer une rotation. Vous pouvez également créer des blocs-notes qui utilisent le point de terminaison de développement.

Vous fournissez les valeurs de configuration pour mettre en service les environnements de développement. Ces valeurs indiquent AWS Glue comment configurer le réseau afin que vous puissiez accéder au point de développement en toute sécurité et que votre point de terminaison puisse accéder à vos magasins de données. Ensuite, vous pouvez créer un bloc-notes qui se connecte au point de terminaison de développement. Vous utilisez votre bloc-notes pour créer et tester votre script ETL.

Utilisez un rôle AWS Identity and Access Management (IAM) doté d'autorisations similaires au rôle IAM que vous utilisez pour exécuter AWS Glue Emplois ETL. Utilisez un cloud privé virtuel (VPC), un sous-réseau et un groupe de sécurité pour créer un point de terminaison de développement qui peut se connecter à vos ressources de données en toute sécurité. Vous générez une paire de clés SSH pour vous connecter à l'environnement de développement à l'aide de SSH.

Vous pouvez créer des points de terminaison de développement pour les données Amazon S3 et au sein d'un VPC que vous pouvez utiliser pour accéder à des ensembles de données à l'aide de JDBC.

Vous pouvez installer un client de bloc-notes Jupyter sur votre ordinateur local et l'utiliser pour déboguer et tester les scripts ETL sur un point de terminaison de développement. Vous pouvez également utiliser un bloc-notes Sagemaker pour créer des scripts ETL JupyterLab en AWS un. Consultez la section [Utiliser un SageMaker bloc-notes avec votre terminal de développement](#).

AWS Glue étiquette EC2 les instances Amazon avec un nom préfixé par `aws-glue-dev-endpoint`.

Vous pouvez configurer un serveur portable sur un terminal de développement pour qu'il s'exécute PySpark avec AWS Glue extensions.

Gestion des identités et des accès pour AWS Glue

AWS Identity and Access Management (IAM) est un outil Service AWS qui permet à un administrateur de contrôler en toute sécurité l'accès aux AWS ressources. Les administrateurs IAM contrôlent qui peut être authentifié (connecté) et autorisé (autorisé) à utiliser les ressources AWS Glue. IAM est un Service AWS outil que vous pouvez utiliser sans frais supplémentaires.

Note

Vous pouvez autoriser l'accès à vos données dans le catalogue de données AWS Glue en utilisant l'une des méthodes suivantes : AWS Glue méthodes ou AWS Lake Formation subventions. Vous pouvez utiliser des politiques AWS Identity and Access Management (IAM) pour définir un contrôle d'accès précis avec AWS Glue méthodes. Lake Formation

utilise un modèle d'autorisations GRANT/REVOKE plus simple similaire aux commandes GRANT/REVOKE dans un système de base de données relationnelle.

Cette section contient des informations sur l'utilisation du AWS Glue méthodes. Pour plus d'informations sur l'utilisation des octrois Lake Formation, veuillez consulter la rubrique [Octroi des autorisations Lake Formation](#) dans le Guide du développeur AWS Lake Formation .

Rubriques

- [Public ciblé](#)
- [Authentification par des identités](#)
- [Gestion des accès à l'aide de politiques](#)
- [Comment AWS Glue fonctionne avec IAM](#)
- [Configuration des autorisations IAM pour AWS Glue](#)
- [AWS Exemples de politiques de contrôle d'accès Glue](#)
- [Octroi de politiques AWS gérées pour AWS Glue](#)
- [Spécification AWS Glue ressource ARNs](#)
- [Octroi d'un accès intercompte](#)
- [Résolution des problèmes d'identité et d'accès à AWS Glue](#)

Public ciblé

La façon dont vous utilisez AWS Identity and Access Management (IAM) varie en fonction du travail que vous effectuez dans AWS Glue.

Utilisateur du service : si vous utilisez le service AWS Glue pour effectuer votre travail, votre administrateur vous fournit les informations d'identification et les autorisations dont vous avez besoin. Au fur et à mesure que vous utilisez de plus en plus de fonctionnalités de AWS Glue pour effectuer votre travail, vous aurez peut-être besoin d'autorisations supplémentaires. En comprenant bien la gestion des accès, vous saurez demander les autorisations appropriées à votre administrateur. Si vous ne pouvez pas accéder à une fonctionnalité dans AWS Glue, veuillez consulter la rubrique [Résolution des problèmes d'identité et d'accès à AWS Glue](#).

Administrateur du service — Si vous êtes responsable des ressources AWS Glue dans votre entreprise, vous avez probablement un accès complet à AWS Glue. C'est à vous de déterminer les fonctionnalités et les ressources de AWS Glue auxquelles les utilisateurs de votre service doivent

accéder. Vous devez ensuite soumettre les demandes à votre administrateur IAM pour modifier les autorisations des utilisateurs de votre service. Consultez les informations sur cette page pour comprendre les concepts de base d'IAM. Pour en savoir plus sur la manière dont votre entreprise peut utiliser IAM with AWS Glue, consultez [Comment AWS Glue fonctionne avec IAM](#).

Administrateur IAM : si vous êtes administrateur IAM, vous souhaitez peut-être en savoir plus sur la manière dont vous pouvez rédiger des politiques pour gérer l'accès à Glue AWS . Pour consulter des exemples de politiques basées sur l'identité AWS Glue que vous pouvez utiliser dans IAM, consultez [Exemples de politiques basées sur l'identité pour Glue AWS](#)

Authentification par des identités

L'authentification est la façon dont vous vous connectez à AWS l'aide de vos informations d'identification. Vous devez être authentifié (connecté à AWS) en tant qu'utilisateur IAM ou en assumant un rôle IAM. Utilisateur racine d'un compte AWS

Vous pouvez vous connecter en AWS tant qu'identité fédérée en utilisant les informations d'identification fournies par le biais d'une source d'identité. AWS IAM Identity Center Les utilisateurs (IAM Identity Center), l'authentification unique de votre entreprise et vos informations d'identification Google ou Facebook sont des exemples d'identités fédérées. Lorsque vous vous connectez avec une identité fédérée, votre administrateur aura précédemment configuré une fédération d'identités avec des rôles IAM. Lorsque vous accédez à AWS l'aide de la fédération, vous assumez indirectement un rôle.

Selon le type d'utilisateur que vous êtes, vous pouvez vous connecter au portail AWS Management Console ou au portail AWS d'accès. Pour plus d'informations sur la connexion à AWS, consultez la section [Comment vous connecter à votre compte Compte AWS dans](#) le guide de Connexion à AWS l'utilisateur.

Si vous y accédez AWS par programmation, AWS fournit un kit de développement logiciel (SDK) et une interface de ligne de commande (CLI) pour signer cryptographiquement vos demandes à l'aide de vos informations d'identification. Si vous n'utilisez pas d' AWS outils, vous devez signer vous-même les demandes. Pour plus d'informations sur l'utilisation de la méthode recommandée pour signer des demandes vous-même, consultez [AWS Signature Version 4 pour les demandes d'API](#) dans le Guide de l'utilisateur IAM.

Quelle que soit la méthode d'authentification que vous utilisez, vous devrez peut-être fournir des informations de sécurité supplémentaires. Par exemple, il vous AWS recommande d'utiliser l'authentification multifactorielle (MFA) pour renforcer la sécurité de votre compte. Pour plus

d'informations, consultez [Authentification multifactorielle](#) dans le Guide de l'utilisateur AWS IAM Identity Center et [Authentification multifactorielle AWS dans IAM](#) dans le Guide de l'utilisateur IAM.

Compte AWS utilisateur root

Lorsque vous créez un Compte AWS, vous commencez par une identité de connexion unique qui donne un accès complet à toutes Services AWS les ressources du compte. Cette identité est appelée utilisateur Compte AWS root et est accessible en vous connectant avec l'adresse e-mail et le mot de passe que vous avez utilisés pour créer le compte. Il est vivement recommandé de ne pas utiliser l'utilisateur racine pour vos tâches quotidiennes. Protégez vos informations d'identification d'utilisateur racine et utilisez-les pour effectuer les tâches que seul l'utilisateur racine peut effectuer. Pour obtenir la liste complète des tâches qui vous imposent de vous connecter en tant qu'utilisateur racine, consultez [Tâches nécessitant des informations d'identification d'utilisateur racine](#) dans le Guide de l'utilisateur IAM.

Identité fédérée

La meilleure pratique consiste à obliger les utilisateurs humains, y compris ceux qui ont besoin d'un accès administrateur, à utiliser la fédération avec un fournisseur d'identité pour accéder à l'aide Services AWS d'informations d'identification temporaires.

Une identité fédérée est un utilisateur de l'annuaire des utilisateurs de votre entreprise, d'un fournisseur d'identité Web AWS Directory Service, du répertoire Identity Center ou de tout utilisateur qui y accède à l'aide des informations d'identification fournies Services AWS par le biais d'une source d'identité. Lorsque des identités fédérées y accèdent Comptes AWS, elles assument des rôles, qui fournissent des informations d'identification temporaires.

Pour une gestion des accès centralisée, nous vous recommandons d'utiliser AWS IAM Identity Center. Vous pouvez créer des utilisateurs et des groupes dans IAM Identity Center, ou vous pouvez vous connecter et synchroniser avec un ensemble d'utilisateurs et de groupes dans votre propre source d'identité afin de les utiliser dans toutes vos applications Comptes AWS et applications. Pour obtenir des informations sur IAM Identity Center, consultez [Qu'est-ce que IAM Identity Center ?](#) dans le Guide de l'utilisateur AWS IAM Identity Center .

Utilisateurs et groupes IAM

Un [utilisateur IAM](#) est une identité au sein de vous Compte AWS qui possède des autorisations spécifiques pour une seule personne ou une seule application. Dans la mesure du possible, nous vous recommandons de vous appuyer sur des informations d'identification temporaires plutôt que de créer des utilisateurs IAM ayant des informations d'identification à long terme telles que des

mots de passe et des clés d'accès. Toutefois, si certains cas d'utilisation spécifiques nécessitent des informations d'identification à long terme avec les utilisateurs IAM, nous vous recommandons d'effectuer une rotation des clés d'accès. Pour plus d'informations, consultez [Rotation régulière des clés d'accès pour les cas d'utilisation nécessitant des informations d'identification](#) dans le Guide de l'utilisateur IAM.

Un [groupe IAM](#) est une identité qui concerne un ensemble d'utilisateurs IAM. Vous ne pouvez pas vous connecter en tant que groupe. Vous pouvez utiliser les groupes pour spécifier des autorisations pour plusieurs utilisateurs à la fois. Les groupes permettent de gérer plus facilement les autorisations pour de grands ensembles d'utilisateurs. Par exemple, vous pouvez nommer un groupe IAMAdminset lui donner les autorisations nécessaires pour administrer les ressources IAM.

Les utilisateurs sont différents des rôles. Un utilisateur est associé de manière unique à une personne ou une application, alors qu'un rôle est conçu pour être endossé par tout utilisateur qui en a besoin. Les utilisateurs disposent d'informations d'identification permanentes, mais les rôles fournissent des informations d'identification temporaires. Pour plus d'informations, consultez [Cas d'utilisation pour les utilisateurs IAM](#) dans le Guide de l'utilisateur IAM.

Rôles IAM

Un [rôle IAM](#) est une identité au sein de votre Compte AWS dotée d'autorisations spécifiques. Le concept ressemble à celui d'utilisateur IAM, mais le rôle IAM n'est pas associé à une personne en particulier. Pour assumer temporairement un rôle IAM dans le AWS Management Console, vous pouvez [passer d'un rôle d'utilisateur à un rôle IAM \(console\)](#). Vous pouvez assumer un rôle en appelant une opération d' AWS API AWS CLI ou en utilisant une URL personnalisée. Pour plus d'informations sur les méthodes d'utilisation des rôles, consultez [Méthodes pour endosser un rôle](#) dans le Guide de l'utilisateur IAM.

Les rôles IAM avec des informations d'identification temporaires sont utiles dans les cas suivants :

- **Accès utilisateur fédéré** : pour attribuer des autorisations à une identité fédérée, vous créez un rôle et définissez des autorisations pour le rôle. Quand une identité externe s'authentifie, l'identité est associée au rôle et reçoit les autorisations qui sont définies par celui-ci. Pour obtenir des informations sur les rôles pour la fédération, consultez [Création d'un rôle pour un fournisseur d'identité tiers \(fédération\)](#) dans le Guide de l'utilisateur IAM. Si vous utilisez IAM Identity Center, vous configurez un jeu d'autorisations. IAM Identity Center met en corrélation le jeu d'autorisations avec un rôle dans IAM afin de contrôler à quoi vos identités peuvent accéder après leur authentification. Pour plus d'informations sur les jeux d'autorisations, consultez [Jeux d'autorisations](#) dans le Guide de l'utilisateur AWS IAM Identity Center .

- Autorisations d'utilisateur IAM temporaires : un rôle ou un utilisateur IAM peut endosser un rôle IAM pour profiter temporairement d'autorisations différentes pour une tâche spécifique.
- Accès intercompte : vous pouvez utiliser un rôle IAM pour permettre à un utilisateur (principal de confiance) d'un compte différent d'accéder aux ressources de votre compte. Les rôles constituent le principal moyen d'accorder l'accès intercompte. Toutefois, dans certains Services AWS cas, vous pouvez associer une politique directement à une ressource (au lieu d'utiliser un rôle comme proxy). Pour en savoir plus sur la différence entre les rôles et les politiques basées sur les ressources pour l'accès intercompte, consultez [Accès intercompte aux ressources dans IAM](#) dans le Guide de l'utilisateur IAM.
- Accès multiservices — Certains Services AWS utilisent des fonctionnalités dans d'autres Services AWS. Par exemple, lorsque vous effectuez un appel dans un service, il est courant que ce service exécute des applications dans Amazon EC2 ou stocke des objets dans Amazon S3. Un service peut le faire en utilisant les autorisations d'appel du principal, un rôle de service ou un rôle lié au service.
- Sessions d'accès direct (FAS) : lorsque vous utilisez un utilisateur ou un rôle IAM pour effectuer des actions AWS, vous êtes considéré comme un mandant. Lorsque vous utilisez certains services, vous pouvez effectuer une action qui initie une autre action dans un autre service. FAS utilise les autorisations du principal appelant et Service AWS, associées Service AWS à la demande, pour adresser des demandes aux services en aval. Les demandes FAS ne sont effectuées que lorsqu'un service reçoit une demande qui nécessite des interactions avec d'autres personnes Services AWS ou des ressources pour être traitée. Dans ce cas, vous devez disposer d'autorisations nécessaires pour effectuer les deux actions. Pour plus de détails sur une politique lors de la formulation de demandes FAS, consultez [Transmission des sessions d'accès](#).
- Rôle de service : il s'agit d'un [rôle IAM](#) attribué à un service afin de réaliser des actions en votre nom. Un administrateur IAM peut créer, modifier et supprimer un rôle de service à partir d'IAM. Pour plus d'informations, consultez [Création d'un rôle pour la délégation d'autorisations à un Service AWS](#) dans le Guide de l'utilisateur IAM.
- Rôle lié à un service — Un rôle lié à un service est un type de rôle de service lié à un. Service AWS Le service peut endosser le rôle afin d'effectuer une action en votre nom. Les rôles liés à un service apparaissent dans votre Compte AWS répertoire et appartiennent au service. Un administrateur IAM peut consulter, mais ne peut pas modifier, les autorisations concernant les rôles liés à un service.
- Applications exécutées sur Amazon EC2 : vous pouvez utiliser un rôle IAM pour gérer les informations d'identification temporaires pour les applications qui s'exécutent sur une EC2 instance et qui envoient des demandes AWS CLI d' AWS API. Cela est préférable au stockage des

clés d'accès dans l' EC2 instance. Pour attribuer un AWS rôle à une EC2 instance et le rendre disponible pour toutes ses applications, vous devez créer un profil d'instance attaché à l'instance. Un profil d'instance contient le rôle et permet aux programmes exécutés sur l' EC2 instance d'obtenir des informations d'identification temporaires. Pour plus d'informations, consultez [Utiliser un rôle IAM pour accorder des autorisations aux applications exécutées sur des EC2 instances Amazon](#) dans le guide de l'utilisateur IAM.

Gestion des accès à l'aide de politiques

Vous contrôlez l'accès en AWS créant des politiques et en les associant à AWS des identités ou à des ressources. Une politique est un objet AWS qui, lorsqu'il est associé à une identité ou à une ressource, définit leurs autorisations. AWS évalue ces politiques lorsqu'un principal (utilisateur, utilisateur root ou session de rôle) fait une demande. Les autorisations dans les politiques déterminent si la demande est autorisée ou refusée. La plupart des politiques sont stockées AWS sous forme de documents JSON. Pour plus d'informations sur la structure et le contenu des documents de politique JSON, consultez [Vue d'ensemble des politiques JSON](#) dans le Guide de l'utilisateur IAM.

Les administrateurs peuvent utiliser les politiques AWS JSON pour spécifier qui a accès à quoi. C'est-à-dire, quel principal peut effectuer des actions sur quelles ressources et dans quelles conditions.

Par défaut, les utilisateurs et les rôles ne disposent d'aucune autorisation. Pour octroyer aux utilisateurs des autorisations d'effectuer des actions sur les ressources dont ils ont besoin, un administrateur IAM peut créer des politiques IAM. L'administrateur peut ensuite ajouter les politiques IAM aux rôles et les utilisateurs peuvent assumer les rôles.

Les politiques IAM définissent les autorisations d'une action, quelle que soit la méthode que vous utilisez pour exécuter l'opération. Par exemple, supposons que vous disposiez d'une politique qui autorise l'action `iam:GetRole`. Un utilisateur appliquant cette politique peut obtenir des informations sur le rôle à partir de AWS Management Console AWS CLI, de ou de l' AWS API.

Politiques basées sur l'identité

Les politiques basées sur l'identité sont des documents de politique d'autorisations JSON que vous pouvez attacher à une identité telle qu'un utilisateur, un groupe d'utilisateurs ou un rôle IAM. Ces politiques contrôlent quel type d'actions des utilisateurs et des rôles peuvent exécuter, sur quelles ressources et dans quelles conditions. Pour découvrir comment créer une politique basée sur

l'identité, consultez [Définition d'autorisations IAM personnalisées avec des politiques gérées par le client](#) dans le Guide de l'utilisateur IAM.

Les politiques basées sur l'identité peuvent être classées comme des politiques en ligne ou des politiques gérées. Les politiques en ligne sont intégrées directement à un utilisateur, groupe ou rôle. Les politiques gérées sont des politiques autonomes que vous pouvez associer à plusieurs utilisateurs, groupes et rôles au sein de votre Compte AWS. Les politiques gérées incluent les politiques AWS gérées et les politiques gérées par le client. Pour découvrir comment choisir entre une politique gérée et une politique en ligne, consultez [Choix entre les politiques gérées et les politiques en ligne](#) dans le Guide de l'utilisateur IAM.

Politiques basées sur les ressources

Les politiques basées sur les ressources sont des documents de politique JSON que vous attachez à une ressource. Par exemple, les politiques de confiance de rôle IAM et les politiques de compartiment Amazon S3 sont des politiques basées sur les ressources. Dans les services qui sont compatibles avec les politiques basées sur les ressources, les administrateurs de service peuvent les utiliser pour contrôler l'accès à une ressource spécifique. Pour la ressource dans laquelle se trouve la politique, cette dernière définit quel type d'actions un principal spécifié peut effectuer sur cette ressource et dans quelles conditions. Vous devez [spécifier un principal](#) dans une politique basée sur les ressources. Les principaux peuvent inclure des comptes, des utilisateurs, des rôles, des utilisateurs fédérés ou. Services AWS

Les politiques basées sur les ressources sont des politiques en ligne situées dans ce service. Vous ne pouvez pas utiliser les politiques AWS gérées par IAM dans une stratégie basée sur les ressources.

Listes de contrôle d'accès (ACLs)

Les listes de contrôle d'accès (ACLs) contrôlent les principaux (membres du compte, utilisateurs ou rôles) autorisés à accéder à une ressource. ACLs sont similaires aux politiques basées sur les ressources, bien qu'elles n'utilisent pas le format de document de politique JSON.

Amazon S3 et AWS WAF Amazon VPC sont des exemples de services compatibles. ACLs Pour en savoir plus ACLs, consultez la [présentation de la liste de contrôle d'accès \(ACL\)](#) dans le guide du développeur Amazon Simple Storage Service.

Autres types de politique

AWS prend en charge d'autres types de politiques moins courants. Ces types de politiques peuvent définir le nombre maximum d'autorisations qui vous sont accordées par des types de politiques plus courants.

- **Limite d'autorisations** : une limite d'autorisations est une fonctionnalité avancée dans laquelle vous définissez le nombre maximal d'autorisations qu'une politique basée sur l'identité peut accorder à une entité IAM (utilisateur ou rôle IAM). Vous pouvez définir une limite d'autorisations pour une entité. Les autorisations en résultant représentent la combinaison des politiques basées sur l'identité d'une entité et de ses limites d'autorisation. Les politiques basées sur les ressources qui spécifient l'utilisateur ou le rôle dans le champ `Principal` ne sont pas limitées par les limites d'autorisations. Un refus explicite dans l'une de ces politiques annule l'autorisation. Pour plus d'informations sur les limites d'autorisations, consultez [Limites d'autorisations pour des entités IAM](#) dans le Guide de l'utilisateur IAM.
- **Politiques de contrôle des services (SCPs)** : SCPs politiques JSON qui spécifient les autorisations maximales pour une organisation ou une unité organisationnelle (UO) dans AWS Organizations. AWS Organizations est un service permettant de regrouper et de gérer de manière centralisée Comptes AWS les multiples propriétés de votre entreprise. Si vous activez toutes les fonctionnalités d'une organisation, vous pouvez appliquer des politiques de contrôle des services (SCPs) à l'un ou à l'ensemble de vos comptes. Le SCP limite les autorisations pour les entités figurant dans les comptes des membres, y compris chacune Utilisateur racine d'un compte AWS d'entre elles. Pour plus d'informations sur les Organizations et consultez SCPs les [politiques de contrôle des services](#) dans le Guide de AWS Organizations l'utilisateur.
- **Politiques de contrôle des ressources (RCPs)** : RCPs politiques JSON que vous pouvez utiliser pour définir le maximum d'autorisations disponibles pour les ressources de vos comptes sans mettre à jour les politiques IAM associées à chaque ressource que vous possédez. Le RCP limite les autorisations pour les ressources des comptes membres et peut avoir un impact sur les autorisations effectives pour les identités, y compris Utilisateur racine d'un compte AWS, qu'elles appartiennent ou non à votre organisation. Pour plus d'informations sur les Organizations RCPs, y compris une liste de ces Services AWS supports RCPs, consultez la section [Resource control policies \(RCPs\)](#) dans le guide de AWS Organizations l'utilisateur.
- **Politiques de séance** : les politiques de séance sont des politiques avancées que vous utilisez en tant que paramètre lorsque vous créez par programmation une séance temporaire pour un rôle ou un utilisateur fédéré. Les autorisations de séance en résultant sont une combinaison des politiques basées sur l'identité de l'utilisateur ou du rôle et des politiques de séance. Les autorisations

peuvent également provenir d'une politique basée sur les ressources. Un refus explicite dans l'une de ces politiques annule l'autorisation. Pour plus d'informations, consultez [Politiques de session](#) dans le Guide de l'utilisateur IAM.

Plusieurs types de politique

Lorsque plusieurs types de politiques s'appliquent à la requête, les autorisations en résultant sont plus compliquées à comprendre. Pour savoir comment AWS déterminer s'il faut autoriser une demande lorsque plusieurs types de politiques sont impliqués, consultez la section [Logique d'évaluation des politiques](#) dans le guide de l'utilisateur IAM.

Comment AWS Glue fonctionne avec IAM

Avant d'utiliser IAM pour gérer l'accès à AWS Glue, découvrez quelles fonctionnalités IAM peuvent être utilisées avec Glue AWS .

Fonctionnalités IAM que vous pouvez utiliser avec Glue AWS

Fonctionnalité IAM	AWS Support Glue
Politiques basées sur l'identité	Oui
Politiques basées sur les ressources	Partielle
Actions de politique	Oui
Ressources de politique	Oui
Clés de condition de politique (spécifiques au service)	Oui
ACLs	Non
ABAC (identifications dans les politiques)	Partielle
Informations d'identification temporaires	Oui
Autorisations de principaux	Non
Rôles de service	Oui

Fonctionnalité IAM	AWS Support Glue
Rôles liés à un service	Non

Pour obtenir une vue d'ensemble de la façon dont AWS Glue et les autres AWS services fonctionnent avec la plupart des fonctionnalités IAM, consultez la section [AWS Services compatibles avec IAM](#) dans le guide de l'utilisateur IAM.

Politiques basées sur l'identité pour Glue AWS

Prend en charge les politiques basées sur l'identité : oui

Les politiques basées sur l'identité sont des documents de politique d'autorisations JSON que vous pouvez attacher à une identité telle qu'un utilisateur, un groupe d'utilisateurs ou un rôle IAM. Ces politiques contrôlent quel type d'actions des utilisateurs et des rôles peuvent exécuter, sur quelles ressources et dans quelles conditions. Pour découvrir comment créer une politique basée sur l'identité, consultez [Définition d'autorisations IAM personnalisées avec des politiques gérées par le client](#) dans le Guide de l'utilisateur IAM.

Avec les politiques IAM basées sur l'identité, vous pouvez spécifier des actions et ressources autorisées ou refusées, ainsi que les conditions dans lesquelles les actions sont autorisées ou refusées. Vous ne pouvez pas spécifier le principal dans une politique basée sur une identité, car celle-ci s'applique à l'utilisateur ou au rôle auquel elle est attachée. Pour découvrir tous les éléments que vous utilisez dans une politique JSON, consultez [Références des éléments de politique JSON IAM](#) dans le Guide de l'utilisateur IAM.

AWS Glue prend en charge les politiques basées sur l'identité (politiques IAM) pour tous AWS Glue opérations. En joignant une politique, vous pouvez accorder des autorisations pour créer, accéder ou modifier une AWS Glue ressource, telle qu'un tableau dans AWS Glue Data Catalog.

Exemples de politiques basées sur l'identité pour Glue AWS

Pour consulter des exemples de politiques basées sur l'identité de AWS Glue, consultez. [Exemples de politiques basées sur l'identité pour Glue AWS](#)

Politiques basées sur les ressources au sein de Glue AWS

Prend en charge les politiques basées sur les ressources : partiel

Les politiques basées sur les ressources sont des documents de politique JSON que vous attachez à une ressource. Par exemple, les politiques de confiance de rôle IAM et les politiques de compartiment Amazon S3 sont des politiques basées sur les ressources. Dans les services qui sont compatibles avec les politiques basées sur les ressources, les administrateurs de service peuvent les utiliser pour contrôler l'accès à une ressource spécifique. Pour la ressource dans laquelle se trouve la politique, cette dernière définit quel type d'actions un principal spécifié peut effectuer sur cette ressource et dans quelles conditions. Vous devez [spécifier un principal](#) dans une politique basée sur les ressources. Les principaux peuvent inclure des comptes, des utilisateurs, des rôles, des utilisateurs fédérés ou. Services AWS

Pour permettre un accès intercompte, vous pouvez spécifier un compte entier ou des entités IAM dans un autre compte en tant que principal dans une politique basée sur les ressources. L'ajout d'un principal intercompte à une politique basée sur les ressources ne représente qu'une partie de l'instauration de la relation d'approbation. Lorsque le principal et la ressource sont différents Comptes AWS, un administrateur IAM du compte sécurisé doit également accorder à l'entité principale (utilisateur ou rôle) l'autorisation d'accéder à la ressource. Pour ce faire, il attache une politique basée sur une identité à l'entité. Toutefois, si une politique basée sur des ressources accorde l'accès à un principal dans le même compte, aucune autre politique basée sur l'identité n'est requise. Pour plus d'informations, consultez [Accès intercompte aux ressources dans IAM](#) dans le Guide de l'utilisateur IAM.

Note

Vous ne pouvez utiliser qu'un AWS Glue politique de ressources pour gérer les autorisations pour les ressources du catalogue de données. Vous ne pouvez l'attacher à aucun autre AWS Glue des ressources telles que des tâches, des déclencheurs, des points de terminaison de développement, des robots d'exploration ou des classificateurs.

Une seule politique basée sur les ressources est autorisée par catalogue et sa taille est limitée à 10 Ko.

Dans AWS Glue, une politique de ressources est attachée à un catalogue, qui est un conteneur virtuel pour tous les types de ressources de catalogue de données mentionnés précédemment. Chaque AWS compte possède un seul catalogue dans une AWS région dont l'identifiant du catalogue est le même que celui du AWS compte. Vous ne pouvez pas supprimer ou modifier un catalogue.

Une politique de ressources est évaluée pour tous les appels d'API au catalogue où le principal de l'appelant est inclus dans le bloc "Principal" du document de politique.

Pour consulter des exemples de politiques basées sur les ressources de AWS Glue, consultez.

[Exemples de politiques basées sur les ressources pour Glue AWS](#)

Actions politiques pour AWS Glue

Prend en charge les actions de politique : oui

Les administrateurs peuvent utiliser les politiques AWS JSON pour spécifier qui a accès à quoi. C'est-à-dire, quel principal peut effectuer des actions sur quelles ressources et dans quelles conditions.

L'élément `Action` d'une politique JSON décrit les actions que vous pouvez utiliser pour autoriser ou refuser l'accès à une politique. Les actions de stratégie portent généralement le même nom que l'opération AWS d'API associée. Il existe quelques exceptions, telles que les actions avec autorisations uniquement qui n'ont pas d'opération API correspondante. Certaines opérations nécessitent également plusieurs actions dans une politique. Ces actions supplémentaires sont nommées actions dépendantes.

Intégration d'actions dans une politique afin d'accorder l'autorisation d'exécuter les opérations associées.

Pour consulter la liste des actions AWS Glue, consultez la section [Actions définies par AWS Glue](#) dans le Service Authorization Reference.

Les actions politiques dans AWS Glue utilisent le préfixe suivant avant l'action :

```
glue
```

Pour indiquer plusieurs actions dans une seule déclaration, séparez-les par des virgules.

```
"Action": [  
    "glue:action1",  
    "glue:action2"  
]
```

Vous pouvez aussi spécifier plusieurs actions à l'aide de caractères génériques (*). Par exemple, pour spécifier toutes les actions qui commencent par le mot `Get`, incluez l'action suivante :


```
"Action": "glue:Get*"
```

Pour afficher des exemples de stratégies, veuillez consulter [AWS Exemples de politiques de contrôle d'accès Glue](#).

Ressources politiques pour AWS Glue

Prend en charge les ressources de politique : oui

Les administrateurs peuvent utiliser les politiques AWS JSON pour spécifier qui a accès à quoi. C'est-à-dire, quel principal peut effectuer des actions sur quelles ressources et dans quelles conditions.

L'élément de politique JSON `Resource` indique le ou les objets auxquels l'action s'applique. Les instructions doivent inclure un élément `Resource` ou `NotResource`. Il est recommandé de définir une ressource à l'aide de son [Amazon Resource Name \(ARN\)](#). Vous pouvez le faire pour des actions qui prennent en charge un type de ressource spécifique, connu sous la dénomination autorisations de niveau ressource.

Pour les actions qui ne sont pas compatibles avec les autorisations de niveau ressource, telles que les opérations de liste, utilisez un caractère générique (*) afin d'indiquer que l'instruction s'applique à toutes les ressources.

```
"Resource": "*"
```

Pour plus d'informations sur la façon de contrôler l'accès aux ressources AWS Glue à ARNs l'aide de [Spécification AWS Glue ressource ARNs](#).

Pour consulter la liste des types de ressources AWS Glue et leurs caractéristiques ARNs, consultez la section [Ressources définies par AWS Glue](#) dans le Service Authorization Reference. Pour savoir quelles actions vous pouvez utiliser pour spécifier l'ARN de chaque ressource, consultez la section [Actions définies par AWS Glue](#).

Clés de conditions de politique pour AWS Glue

Prend en charge les clés de condition de politique spécifiques au service : oui

Les administrateurs peuvent utiliser les politiques AWS JSON pour spécifier qui a accès à quoi. C'est-à-dire, quel principal peut effectuer des actions sur quelles ressources et dans quelles conditions.

L'élément Condition (ou le bloc Condition) vous permet de spécifier des conditions lorsqu'une instruction est appliquée. L'élément Condition est facultatif. Vous pouvez créer des expressions conditionnelles qui utilisent des [opérateurs de condition](#), tels que les signes égal ou inférieur à, pour faire correspondre la condition de la politique aux valeurs de la demande.

Si vous spécifiez plusieurs éléments Condition dans une instruction, ou plusieurs clés dans un seul élément Condition, AWS les évalue à l'aide d'une opération AND logique. Si vous spécifiez plusieurs valeurs pour une seule clé de condition, AWS évalue la condition à l'aide d'une OR opération logique. Toutes les conditions doivent être remplies avant que les autorisations associées à l'instruction ne soient accordées.

Vous pouvez aussi utiliser des variables d'espace réservé quand vous spécifiez des conditions. Par exemple, vous pouvez accorder à un utilisateur IAM l'autorisation d'accéder à une ressource uniquement si elle est balisée avec son nom d'utilisateur IAM. Pour plus d'informations, consultez [Éléments d'une politique IAM : variables et identifications](#) dans le Guide de l'utilisateur IAM.

AWS prend en charge les clés de condition globales et les clés de condition spécifiques au service. Pour voir toutes les clés de condition AWS globales, voir les clés de [contexte de condition AWS globales](#) dans le guide de l'utilisateur IAM.

Pour consulter la liste des clés de condition AWS Glue, voir [Clés de condition pour AWS Glue](#) dans le Service Authorization Reference. Pour savoir avec quelles actions et ressources vous pouvez utiliser une clé de condition, consultez [Actions définies par AWS Glue](#).

Pour afficher des exemples de stratégies, veuillez consulter [Contrôler les paramètres à l'aide de clés de condition ou de contexte](#).

ACLs dans AWS Glue

Supports ACLs : Non

Les listes de contrôle d'accès (ACLs) contrôlent les principaux (membres du compte, utilisateurs ou rôles) autorisés à accéder à une ressource. ACLs sont similaires aux politiques basées sur les ressources, bien qu'elles n'utilisent pas le format de document de politique JSON.

ABAC avec Glue AWS

Prend en charge ABAC (identifications dans les politiques) : partiellement

Le contrôle d'accès par attributs (ABAC) est une stratégie d'autorisation qui définit des autorisations en fonction des attributs. Dans AWS, ces attributs sont appelés balises. Vous pouvez associer des

balises aux entités IAM (utilisateurs ou rôles) et à de nombreuses AWS ressources. L'étiquetage des entités et des ressources est la première étape d'ABAC. Vous concevez ensuite des politiques ABAC pour autoriser des opérations quand l'identification du principal correspond à celle de la ressource à laquelle il tente d'accéder.

L'ABAC est utile dans les environnements qui connaissent une croissance rapide et pour les cas où la gestion des politiques devient fastidieuse.

Pour contrôler l'accès basé sur des étiquettes, vous devez fournir les informations d'étiquette dans l'[élément de condition](#) d'une politique utilisant les clés de condition `aws:ResourceTag/key-name`, `aws:RequestTag/key-name` ou `aws:TagKeys`.

Si un service prend en charge les trois clés de condition pour tous les types de ressources, alors la valeur pour ce service est Oui. Si un service prend en charge les trois clés de condition pour certains types de ressources uniquement, la valeur est Partielle.

Pour plus d'informations sur ABAC, consultez [Définition d'autorisations avec l'autorisation ABAC](#) dans le Guide de l'utilisateur IAM. Pour accéder à un didacticiel décrivant les étapes de configuration de l'ABAC, consultez [Utilisation du contrôle d'accès par attributs \(ABAC\)](#) dans le Guide de l'utilisateur IAM.

Important

Les clés contextuelles de condition s'appliquent uniquement à AWS Glue Actions d'API sur les robots d'exploration, les tâches, les déclencheurs et les points de terminaison de développement. Pour plus d'informations sur les opérations d'API concernées, consultez la section [Clés de condition pour AWS Glue](#).

Le AWS Glue Les opérations de l'API Data Catalog ne prennent actuellement pas en charge les clés de contexte de condition `aws:UserAgent` globale `aws:referer` et globale.

Pour visualiser un exemple de politique basée sur l'identité permettant de limiter l'accès à une ressource en fonction des balises de cette ressource, consultez [Octoyer l'accès à l'aide de balises](#).

Utiliser des informations d'identification temporaires avec AWS Glue

Prend en charge les informations d'identification temporaires : oui

Certains Services AWS ne fonctionnent pas lorsque vous vous connectez à l'aide d'informations d'identification temporaires. Pour plus d'informations, y compris celles qui Services AWS fonctionnent

avec des informations d'identification temporaires, consultez Services AWS la section relative à l'utilisation [d'IAM](#) dans le guide de l'utilisateur d'IAM.

Vous utilisez des informations d'identification temporaires si vous vous connectez à l' AWS Management Console aide d'une méthode autre qu'un nom d'utilisateur et un mot de passe. Par exemple, lorsque vous accédez à AWS l'aide du lien d'authentification unique (SSO) de votre entreprise, ce processus crée automatiquement des informations d'identification temporaires. Vous créez également automatiquement des informations d'identification temporaires lorsque vous vous connectez à la console en tant qu'utilisateur, puis changez de rôle. Pour plus d'informations sur le changement de rôle, consultez [Passage d'un rôle utilisateur à un rôle IAM \(console\)](#) dans le Guide de l'utilisateur IAM.

Vous pouvez créer manuellement des informations d'identification temporaires à l'aide de l' AWS API AWS CLI or. Vous pouvez ensuite utiliser ces informations d'identification temporaires pour y accéder AWS. AWS recommande de générer dynamiquement des informations d'identification temporaires au lieu d'utiliser des clés d'accès à long terme. Pour plus d'informations, consultez [Informations d'identification de sécurité temporaires dans IAM](#).

Autorisations principales interservices pour AWS Glue

Prend en charge les sessions d'accès direct (FAS) : oui

Lorsque vous utilisez un utilisateur ou un rôle IAM pour effectuer des actions AWS, vous êtes considéré comme un mandant. Lorsque vous utilisez certains services, vous pouvez effectuer une action qui initie une autre action dans un autre service. FAS utilise les autorisations du principal appelant et Service AWS, associées Service AWS à la demande, pour adresser des demandes aux services en aval. Les demandes FAS ne sont effectuées que lorsqu'un service reçoit une demande qui nécessite des interactions avec d'autres personnes Services AWS ou des ressources pour être traitée. Dans ce cas, vous devez disposer d'autorisations nécessaires pour effectuer les deux actions. Pour plus de détails sur une politique lors de la formulation de demandes FAS, consultez [Transmission des sessions d'accès](#).

Fonctions du service pour AWS Glue

Prend en charge les rôles de service : oui

Un rôle de service est un [rôle IAM](#) qu'un service endosse pour accomplir des actions en votre nom. Un administrateur IAM peut créer, modifier et supprimer un rôle de service à partir d'IAM. Pour plus d'informations, consultez [Création d'un rôle pour la délégation d'autorisations à un Service AWS](#) dans le Guide de l'utilisateur IAM.

 Warning

La modification des autorisations associées à un rôle de service peut perturber les fonctionnalités de AWS Glue. Modifiez les rôles de service uniquement lorsque AWS Glue fournit des instructions à cet effet.

Pour obtenir des instructions détaillées sur la création d'un rôle de service pour AWS Glue, reportez-vous [Étape 1 : créer une politique IAM pour AWS Glue web](#) aux sections et [Étape 2 : créer un rôle IAM pour AWS Glue](#).

Rôles liés à un service pour Glue AWS

Prend en charge les rôles liés à un service : non

Un rôle lié à un service est un type de rôle de service lié à un. Service AWS Le service peut endosser le rôle afin d'effectuer une action en votre nom. Les rôles liés à un service apparaissent dans votre Compte AWS répertoire et appartiennent au service. Un administrateur IAM peut consulter, mais ne peut pas modifier, les autorisations concernant les rôles liés à un service.

Pour plus d'informations sur la création ou la gestion des rôles liés à un service, consultez [Services AWS qui fonctionnent avec IAM](#). Recherchez un service dans le tableau qui inclut un Yes dans la colonne Rôle lié à un service. Choisissez le lien Oui pour consulter la documentation du rôle lié à ce service.

Configuration des autorisations IAM pour AWS Glue

Vous utilisez AWS Identity and Access Management (IAM) pour définir des politiques et des rôles qui AWS Glue utilise pour accéder aux ressources. Les étapes suivantes vous guident à travers les différentes options de configuration des autorisations pour AWS Glue. En fonction de vos besoins professionnels, vous pouvez avoir besoin d'accroître ou de limiter l'accès à vos ressources.

 Note

Pour commencer à utiliser les autorisations IAM de base pour la AWS Glue place, consultez [Configuration des autorisations IAM pour AWS Glue](#).

1. [Créez une politique IAM pour AWS Glue service](#) : créez une politique de service qui autorise l'accès à AWS Glue ressources.
2. [Créez un rôle IAM pour AWS Glue](#): créez un rôle IAM et associez le AWS Glue une politique de service et une politique pour vos ressources Amazon Simple Storage Service (Amazon S3) utilisées par AWS Glue.
3. [Associer une politique aux utilisateurs ou aux groupes qui accèdent AWS Glue](#): associez des politiques à tous les utilisateurs ou groupes qui se connectent au AWS Glue console.
4. [Créer une politique IAM pour les blocs-notes](#) : créez une politique de serveur de bloc-notes à utiliser lors de la création de serveurs de bloc-notes sur les points de terminaison de développement.
5. [Créer un rôle IAM pour les blocs-notes](#) : créez un rôle IAM et attachez la politique de serveur de bloc-notes.
6. [Création d'une politique IAM pour les blocs-notes Amazon SageMaker AI](#) : créez une politique IAM à utiliser lors de la création de blocs-notes Amazon SageMaker AI sur les terminaux de développement.
7. [Création d'un rôle IAM pour les blocs-notes Amazon SageMaker AI](#) : créez un rôle IAM et joignez la politique d'octroi d'autorisations lors de la création de blocs-notes Amazon SageMaker AI sur les terminaux de développement.

Étape 1 : créer une politique IAM pour AWS Glue web

Pour toute opération qui accède aux données d'une autre AWS ressource, telle que l'accès à vos objets dans Amazon S3, AWS Glue a besoin d'une autorisation pour accéder à la ressource en votre nom. Vous fournissez ces autorisations en utilisant AWS Identity and Access Management (IAM).

Note

Vous pouvez ignorer cette étape si vous utilisez la politique AWS gérée **AWSGlueServiceRole**.

Au cours de cette étape, vous créez une politique similaire à **AWSGlueServiceRole**. Vous pouvez consulter la version la plus récente de **AWSGlueServiceRole** sur la console IAM.

Pour créer une politique IAM pour AWS Glue

Cette politique autorise certaines actions Amazon S3 visant à gérer les ressources de votre compte qui sont nécessaires pour AWS Glue lorsqu'il assume le rôle en utilisant cette politique. Certaines des ressources spécifiées dans cette politique font référence à des noms par défaut utilisés par AWS Glue pour les compartiments Amazon S3, les scripts ETL Amazon S3, CloudWatch les journaux et les EC2 ressources Amazon. Pour plus de simplicité, AWS Glue écrit certains objets Amazon S3 dans des compartiments de votre compte avec le préfixe `aws-glue-` * par défaut.

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.
2. Dans le volet de navigation de gauche, choisissez Politiques.
3. Sélectionnez Créer une politique.
4. Sur l'écran Créer une politique, accédez à un onglet pour modifier le fichier JSON. Créez un document de politique avec les instructions JSON suivantes, puis sélectionnez Examiner une politique.

Note

Ajoutez les permissions requises pour les ressources Amazon S3. Vous pouvez vouloir définir la portée de la section des ressources de votre politique d'accès uniquement aux ressources qui sont requises.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:*",
        "s3:GetBucketLocation",
        "s3:ListBucket",
        "s3:ListAllMyBuckets",
        "s3:GetBucketAcl",
        "ec2:DescribeVpcEndpoints",
        "ec2:DescribeRouteTables",
        "ec2:CreateNetworkInterface",
        "ec2>DeleteNetworkInterface",
```

```

        "ec2:DescribeNetworkInterfaces",
        "ec2:DescribeSecurityGroups",
        "ec2:DescribeSubnets",
        "ec2:DescribeVpcAttribute",
        "iam:ListRolePolicies",
        "iam:GetRole",
        "iam:GetRolePolicy",
        "cloudwatch:PutMetricData"
    ],
    "Resource": [
        "*"
    ]
},
{
    "Effect": "Allow",
    "Action": [
        "s3:CreateBucket",
        "s3:PutBucketPublicAccessBlock"
    ],
    "Resource": [
        "arn:aws:s3:::aws-glue-*"
    ]
},
{
    "Effect": "Allow",
    "Action": [
        "s3:GetObject",
        "s3:PutObject",
        "s3:DeleteObject"
    ],
    "Resource": [
        "arn:aws:s3:::aws-glue-*/**",
        "arn:aws:s3:::*/**aws-glue-*/**"
    ]
},
{
    "Effect": "Allow",
    "Action": [
        "s3:GetObject"
    ],
    "Resource": [
        "arn:aws:s3:::crawler-public*",
        "arn:aws:s3:::aws-glue-*"
    ]
}

```



```
    },
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents",
        "logs:AssociateKmsKey"
      ],
      "Resource": [
        "arn:aws:logs:*:*:log-group:/aws-glue/*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "ec2:CreateTags",
        "ec2>DeleteTags"
      ],
      "Condition": {
        "ForAllValues:StringEquals": {
          "aws:TagKeys": [
            "aws-glue-service-resource"
          ]
        }
      },
      "Resource": [
        "arn:aws:ec2:*:*:network-interface/*",
        "arn:aws:ec2:*:*:security-group/*",
        "arn:aws:ec2:*:*:instance/*"
      ]
    }
  ]
}
```

Le tableau suivant décrit les autorisations accordées par cette politique.

Action	Ressource	Description
"glue:*"	"*"	Accorde l'autorisation de tout exécuter AWS Glue Opérations d'API.

Action	Ressource	Description
"s3:GetBucketLocation", "s3:ListBucket", "s3:ListAllMyBuckets", "s3:GetBucketAcl",	"*"	Permet de répertorier les compartiments Amazon S3 des crawlers, des tâches, des points de terminaison de développement et des serveurs de bloc-notes.
"ec2:DescribeVpcEndpoints", "ec2:DescribeRouteTables", "ec2:CreateNetworkInterface", "ec2:DeleteNetworkInterface", "ec2:DescribeNetworkInterfaces", "ec2:DescribeSecurityGroups", "ec2:DescribeSubnets", "ec2:DescribeVpcAttribute",	"*"	Permet de configurer des éléments du EC2 réseau Amazon, tels que des clouds privés virtuels (VPCs) lors de l'exécution de tâches, de robots d'exploration et de points de terminaison de développement.
"iam:ListRolePolicies", "iam:GetRole", "iam:GetRolePolicy"	"*"	Permet de répertorier les rôles IAM des crawlers, des tâches, des points de terminaison de développement et des serveurs de bloc-notes.
"cloudwatch:PutMetricData"	"*"	Permet d'écrire CloudWatch des métriques pour les tâches.

Action	Ressource	Description
"s3:CreateBucket", "s3:PutBucketPublicAccessBlock"	"arn:aws:s3:::aws-glue-*)"	Permet de créer de compartiments Amazon S3 dans votre compte à partir de tâches et de serveurs de bloc-notes. Convention de dénomination : utilise les dossiers Amazon S3 nommés aws-glue-. Permet AWS Glue pour créer des compartiments qui bloquent l'accès public.
"s3:GetObject", "s3:PutObject", "s3:DeleteObject"	"arn:aws:s3:::aws-glue-*/*", "arn:aws:s3:::*/*aws-glue-*/*"	Permet d'obtenir, d'ajouter et de supprimer des objets Amazon S3 dans votre compte lors du stockage d'objets, tel que des scripts ETL et des emplacements de serveurs de bloc-notes. Convention de dénomination : accorde l'autorisation aux compartiments ou dossiers Amazon S3 dont les noms portent le préfixe aws-glue-.

Action	Ressource	Description
"s3:GetObject"	"arn:aws:s3:::crawler-public*", "arn:aws:s3:::aws-glue-*"	Permet d'obtenir des objets Amazon S3 utilisés par des exemples et des didacticiels d'crawlers et de tâches. Convention de dénomination : les noms de compartiments Amazon S3 dont le nom commence par crawler-public et aws-glue-.
"logs:CreateLogGroup", "logs:CreateLogStream", "logs:PutLogEvents"	"arn:aws:logs:*:*:log-group:/aws-glue/*"	Permet d'écrire des journaux dans CloudWatch Logs. Convention de dénomination : AWS Glue écrit des journaux dans des groupes de journaux dont le nom commence par aws-glue.
"ec2:CreateTags", "ec2:DeleteTags"	"arn:aws:ec2:*:*:network-interface/*", "arn:aws:ec2:*:*:security-group/*", "arn:aws:ec2:*:*:instance/*"	Permet de baliser les EC2 ressources Amazon créées pour les points de terminaison de développement. Convention de dénomination : AWS Glue étiquette les interfaces EC2 réseau, les groupes de sécurité et les instances Amazon avec aws-glue-service-resource.

- Sur l'écran Review policy (Examiner la politique), saisissez votre Policy Name (Nom de politique), par exemple, GlueServiceRolePolicy. Saisissez éventuellement une description, et lorsque vous êtes satisfait de la politique, sélectionnez Créer une politique.

Étape 2 : créer un rôle IAM pour AWS Glue

Vous devez accorder à votre rôle IAM des autorisations qui AWS Glue peut assumer lorsque vous appelez d'autres services en votre nom. Cela inclut l'accès à Amazon S3 pour toutes les sources, cibles, scripts et répertoires temporaires que vous utilisez avec AWS Glue. Les robots d'exploration, les jobs et les terminaux de développement ont besoin d'une autorisation.

Vous fournissez ces autorisations en utilisant AWS Identity and Access Management (IAM). Ajoutez une politique au rôle IAM auquel vous passez AWS Glue.

Pour créer un rôle IAM pour AWS Glue

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.
2. Dans le volet de navigation de gauche, choisissez Rôles.
3. Choisissez Créer un rôle.
4. Choisissez le AWS service comme type d'entité de confiance. Ensuite, pour le service ou le cas d'utilisation, recherchez et choisissez AWS Glue. Choisissez Next.
5. Sur la page Ajouter des autorisations, choisissez les politiques qui contiennent les autorisations requises ; par exemple, la stratégie AWS gérée AWSGlueServiceRole pour les applications générales AWS Glue les autorisations et la politique AWS gérée AmazonS3 FullAccess pour l'accès aux ressources Amazon S3. Ensuite, sélectionnez Suivant.

Note

Assurez-vous que l'une des politiques de ce rôle accorde des autorisations à vos sources et cibles Amazon S3. Vous pouvez vouloir fournir votre propre politique pour l'accès à certaines ressources Amazon S3. Les sources de données nécessitent les autorisations `s3:ListBucket` et `s3:GetObject`. Les sources de données nécessitent les autorisations `s3:ListBucket`, `s3:PutObject` et `s3:DeleteObject`. Pour plus d'informations sur la création d'une politique Amazon S3 pour vos ressources, consultez [Spécification des ressources d'une politique](#). Pour obtenir un exemple de politique Amazon S3, consultez notre billet de blog [Writing IAM Policies: How to Grant Access to an Amazon S3 Bucket](#).

Si vous prévoyez d'accéder aux sources et cibles Amazon S3 chiffrées avec SSE-KMS, joignez une politique qui permet AWS Glue des robots d'exploration, des tâches et des points de terminaison de développement pour déchiffrer les données. Pour plus

d'informations, voir [Protection des données à l'aide du chiffrement côté serveur avec des clés AWS KMS gérées \(SSE-KMS\)](#).

Voici un exemple.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "kms:Decrypt"
      ],
      "Resource": [
        "arn:aws:kms:*:account-id-without-hyphens:key/key-id"
      ]
    }
  ]
}
```

6. Donnez un nom à votre rôle et ajoutez une description (facultatif), puis passez en revue la politique de confiance et les autorisations. Pour Role name (Nom du rôle), indiquez le nom de votre rôle, par exemple, `AWSGlueServiceRoleDefault`. Créez le rôle avec le nom préfixé par la chaîne `AWSGlueServiceRole` pour permettre au rôle d'être transmis des utilisateurs de la console au service. AWS Glue les politiques fournies prévoient que les rôles de service IAM doivent commencer `AWSGlueServiceRole` par. Sinon, vous devez ajouter une politique accordant à vos utilisateurs l'autorisation `iam:PassRole` afin que les rôles IAM correspondent à votre convention de dénomination. Choisissez Create Role (Créer un rôle).

Note

Lorsque vous créez un bloc-notes avec un rôle, ce rôle est ensuite transmis à des séances interactives afin que le même rôle puisse être utilisé aux deux endroits. En tant que tel, l'autorisation `iam:PassRole` doit faire partie de la politique du rôle.

Créez une politique pour votre rôle à l'aide de l'exemple suivant. Remplacez le numéro de compte par le vôtre et le nom du rôle.

```
{
  "Version": "2012-10-17",
  "Statement": [
```

```
{
  "Effect": "Allow",
  "Action": "iam:PassRole",
  "Resource": "arn:aws:iam::090000000210:role/<role_name>"
}
```

7. Ajoutez des tags à votre rôle (facultatif). Les balises sont des paires clé-valeur que vous pouvez ajouter aux AWS ressources pour identifier, organiser ou rechercher des ressources. Puis, choisissez Créer un rôle.

Étape 3 : associer une politique aux utilisateurs ou aux groupes qui accèdent AWS Glue

L'administrateur doit attribuer des autorisations à tous les utilisateurs, groupes ou rôles à l'aide du AWS Glue console ou AWS Command Line Interface (AWS CLI). Vous fournissez ces autorisations grâce à AWS Identity and Access Management (IAM) par le biais des politiques. Cette étape décrit l'attribution d'autorisations à des utilisateurs ou groupes.

Une fois cette étape terminée, les politiques suivantes seront associées à votre utilisateur ou groupe :

- La politique AWS gérée **AWSGlueConsoleFullAccess** ou la politique personnalisée **GlueConsoleAccessPolicy**
- **AWSGlueConsoleSageMakerNotebookFullAccess**
- **CloudWatchLogsReadOnlyAccess**
- **AWSCloudFormationReadOnlyAccess**
- **AmazonAthenaFullAccess**

Associer une politique en ligne et l'intégrer à un utilisateur ou à un groupe

Vous pouvez associer une politique AWS gérée ou une politique intégrée à un utilisateur ou à un groupe pour accéder au AWS Glue console. Certaines des ressources spécifiées dans cette politique font référence aux noms par défaut utilisés par AWS Glue pour les compartiments Amazon S3, les scripts ETL Amazon S3 AWS CloudFormation, CloudWatch les journaux et les EC2 ressources

Amazon. Pour plus de simplicité, AWS Glue écrit certains objets Amazon S3 dans des compartiments de votre compte avec le préfixe `aws-glue-` * par défaut.

 Note

Vous pouvez ignorer cette étape si vous utilisez la politique AWS gérée **AWSGlueConsoleFullAccess**.

 Important

AWS Glue a besoin d'une autorisation pour assumer un rôle utilisé pour effectuer un travail en votre nom. Pour ce faire, vous ajoutez les **iam:PassRole** autorisations à votre AWS Glue utilisateurs ou groupes. Cette politique accorde l'autorisation aux rôles commençant `AWSGlueServiceRole` par AWS Glue les rôles de service et `AWSGlueServiceNotebookRole` pour les rôles requis lors de la création d'un serveur de blocs-notes. Vous pouvez également créer votre propre politique pour les autorisations `iam:PassRole`, conforme à votre convention de dénomination.

Conformément aux meilleures pratiques de sécurité, il est recommandé de restreindre l'accès en renforçant les politiques afin de restreindre davantage l'accès aux compartiments et aux groupes de Amazon CloudWatch journaux Amazon S3. Pour obtenir un exemple de politique Amazon S3, consultez notre billet de blog [Writing IAM Policies: How to Grant Access to an Amazon S3 Bucket](#).

Au cours de cette étape, vous créez une politique similaire à `AWSGlueConsoleFullAccess`. Vous pouvez consulter la version la plus récente de `AWSGlueConsoleFullAccess` sur la console IAM.

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.
2. Dans le volet de navigation, choisissez Utilisateurs ou Groupes d'utilisateurs.
3. Dans la liste, sélectionnez le nom de l'utilisateur ou du groupe auquel intégrer une politique.
4. Sélectionnez l'onglet Autorisations et, si nécessaire, développez la section Politiques d'autorisations.
5. Cliquez sur le lien Add Inline policy (Ajouter une politique en ligne).

6. Sur l'écran Créer une politique, accédez à un onglet pour modifier le fichier JSON. Créez un document de politique avec les instructions JSON suivantes, puis sélectionnez Examiner une politique.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:*",
        "redshift:DescribeClusters",
        "redshift:DescribeClusterSubnetGroups",
        "iam:ListRoles",
        "iam:ListUsers",
        "iam:ListGroups",
        "iam:ListRolePolicies",
        "iam:GetRole",
        "iam:GetRolePolicy",
        "iam:ListAttachedRolePolicies",
        "ec2:DescribeSecurityGroups",
        "ec2:DescribeSubnets",
        "ec2:DescribeVpcs",
        "ec2:DescribeVpcEndpoints",
        "ec2:DescribeRouteTables",
        "ec2:DescribeVpcAttribute",
        "ec2:DescribeKeyPairs",
        "ec2:DescribeInstances",
        "rds:DescribeDBInstances",
        "rds:DescribeDBClusters",
        "rds:DescribeDBSubnetGroups",
        "s3:ListAllMyBuckets",
        "s3:ListBucket",
        "s3:GetBucketAcl",
        "s3:GetBucketLocation",
        "cloudformation:DescribeStacks",
        "cloudformation:GetTemplateSummary",
        "dynamodb:ListTables",
        "kms:ListAliases",
        "kms:DescribeKey",
        "cloudwatch:GetMetricData",
        "cloudwatch:ListDashboards"
      ]
    }
  ],
}
```

```

        "Resource": [
            "*"
        ]
    },
    {
        "Effect": "Allow",
        "Action": [
            "s3:GetObject",
            "s3:PutObject"
        ],
        "Resource": [
            "arn:aws:s3:::*/aws-glue-*/",
            "arn:aws:s3:::aws-glue-*"
        ]
    },
    {
        "Effect": "Allow",
        "Action": [
            "tag:GetResources"
        ],
        "Resource": [
            "*"
        ]
    },
    {
        "Effect": "Allow",
        "Action": [
            "s3:CreateBucket",
            "s3:PutBucketPublicAccessBlock"
        ],
        "Resource": [
            "arn:aws:s3:::aws-glue-*"
        ]
    },
    {
        "Effect": "Allow",
        "Action": [
            "logs:GetLogEvents"
        ],
        "Resource": [
            "arn:aws:logs:*:*/aws-glue/*"
        ]
    },
    {
        "Effect": "Allow",

```

```

        "Action": [
            "cloudformation:CreateStack",
            "cloudformation>DeleteStack"
        ],
        "Resource": "arn:aws:cloudformation:*:*:stack/aws-glue*/*"
    },
    {
        "Effect": "Allow",
        "Action": [
            "ec2:RunInstances"
        ],
        "Resource": [
            "arn:aws:ec2:*:*:instance/*",
            "arn:aws:ec2:*:*:key-pair/*",
            "arn:aws:ec2:*:*:image/*",
            "arn:aws:ec2:*:*:security-group/*",
            "arn:aws:ec2:*:*:network-interface/*",
            "arn:aws:ec2:*:*:subnet/*",
            "arn:aws:ec2:*:*:volume/*"
        ]
    },
    {
        "Action": [
            "iam:PassRole"
        ],
        "Effect": "Allow",
        "Resource": "arn:aws:iam:*:*:role/AWSGlueServiceRole*",
        "Condition": {
            "StringLike": {
                "iam:PassedToService": [
                    "glue.amazonaws.com"
                ]
            }
        }
    },
    {
        "Action": [
            "iam:PassRole"
        ],
        "Effect": "Allow",
        "Resource": "arn:aws:iam:*:*:role/AWSGlueServiceNotebookRole*",
        "Condition": {
            "StringLike": {
                "iam:PassedToService": [

```

```
        "ec2.amazonaws.com"
      ]
    }
  },
  {
    "Action": [
      "iam:PassRole"
    ],
    "Effect": "Allow",
    "Resource": [
      "arn:aws:iam::*:role/service-role/AWSGlueServiceRole*"
    ],
    "Condition": {
      "StringLike": {
        "iam:PassedToService": [
          "glue.amazonaws.com"
        ]
      }
    }
  }
]
```

Le tableau suivant décrit les autorisations accordées par cette politique.

Action	Ressource	Description
"glue:*"	"*"	Accorde l'autorisation de tout exécuter AWS Glue Opérations d'API. Si vous avez déjà créé votre politique sans l'action "glue:*", vous devez ajouter les autorisations individuelles suivantes à votre politique : • « colle : ListCrawlers » • « colle : BatchGetCrawlers » • « colle : ListTriggers » • « colle : BatchGetTriggers » • « colle : ListDevEndpoints » • « colle : BatchGetDevEndpoints » • « colle : ListJobs » • « colle : BatchGetJobs »
"redshift:DescribeClusters", "redshift:DescribeClusterSubnetGroups"	"*"	Permet de créer des connexions à Amazon Redshift.

Action	Ressource	Description
"iam:ListRoles", "iam:ListRolePolicies", "iam:GetRole", "iam:GetRolePolicy", "iam:ListAttachedRolePolicies"	"*"	Permet de répertorier les rôles IAM lors de l'utilisation d'crawlers, de tâches, de points de terminaison de développement et de serveurs de bloc-notes.
"ec2:DescribeSecurityGroups", "ec2:DescribeSubnets", "ec2:DescribeVpcs", "ec2:DescribeVpcEndpoints", "ec2:DescribeRouteTables", "ec2:DescribeVpcAttribute", "ec2:DescribeKeyPairs", "ec2:DescribeInstances"	"*"	Permet de configurer des éléments du EC2 réseau Amazon, tels que lors de l'exécution de tâches VPCs, de robots d'exploration et de points de terminaison de développement.
"rds:DescribeDBInstances"	"*"	Permet de créer des connexions à Amazon RDS.
"s3:ListAllMyBuckets", "s3:ListBucket", "s3:GetBucketAcl", "s3:GetBucketLocation"	"*"	Permet de répertorier les compartiments Amazon S3 lors de l'utilisation d'crawlers, de tâches, de points de terminaison de développement et de serveurs de bloc-notes.
"dynamodb:ListTables"	"*"	Autorise la création d'une liste des tables DynamoDB.

Action	Ressource	Description
"kms:ListAliases", "kms:DescribeKey"	"*"	Permet l'utilisation de clés KMS.
"cloudwatch:GetMetricData", "cloudwatch:ListDashboards"	"*"	Permet de travailler avec CloudWatch des métriques.
"s3:GetObject", "s3:PutObject"	"arn:aws:s3:::aws-glue-*/*", "arn:aws:s3::: */*aws-glue-*/*", "arn:aws:s3:::aws-glue-*"	Permet d'obtenir et d'ajouter des objets Amazon S3 dans votre compte lors du stockage d'objets, tel que des scripts ETL et des emplacements de serveurs de bloc-notes. Convention de dénomination : accorde l'autorisation aux compartiments ou dossiers Amazon S3 dont les noms portent le préfixe aws-glue-.
"tag:GetResources"	"*"	Permet de récupérer des AWS tags.

Action	Ressource	Description
"s3:CreateBucket", "s3:PutBucketPublicAccessBlock"	"arn:aws:s3::: aws-glue- *"	Permet de créer un compartiment Amazon S3 dans votre compte lors du stockage d'objets, tel que des scripts ETL et des emplacements de serveurs de bloc-notes Convention de dénomination : accorde l'autorisation aux compartiments Amazon S3 dont les noms portent le préfixe aws-glue-. Permet AWS Glue pour créer des compartiments qui bloquent l'accès public.
"logs:GetLogEvents"	"arn:aws:logs:*:*: /aws-glue/*"	Permet de récupérer les CloudWatch journaux. Convention de dénomination : AWS Glue écrit des journaux dans des groupes de journaux dont le nom commence par aws-glue-.

Action	Ressource	Description
"cloudformation:CreateStack", "cloudformation:DeleteStack"	"arn:aws:cloudformation:*:*:stack/aws-glue*/"	Permet de gérer les AWS CloudFormation piles lorsque vous travaillez avec des serveurs portables. Convention de dénomination : AWS Glue crée des piles dont le nom commence par aws-glue.
"ec2:RunInstances"	"arn:aws:ec2:*:*:instance/*", "arn:aws:ec2:*:*:key-pair/*", "arn:aws:ec2:*:*:image/*", "arn:aws:ec2:*:*:security-group/*", "arn:aws:ec2:*:*:network-interface/*", "arn:aws:ec2:*:*:subnet/*", "arn:aws:ec2:*:*:volume/*"	Autorise l'exécution de points de terminaison de développement et de serveurs de blocs-notes.
"iam:PassRole"	"arn:aws:iam:*:*:role/AWSGlueServiceRole"	Autorise AWS Glue pour assumer PassRole l'autorisation pour les rôles commençant par AWSGlueServiceRole.

Action	Ressource	Description
"iam:PassRole"	"arn:aws:iam::*:role/ AWSGlueServiceNotebookRole*"	Permet EC2 à Amazon d'obtenir PassRole l'autorisation pour les rôles commençant parAWSGlueServiceNotebookRole .
"iam:PassRole"	"arn:aws:iam::*:role/service-role/ AWSGlueServiceRole*"	Autorise AWS Glue pour assumer PassRole l'autorisation pour les rôles commençant parservice-role/ AWSGlueServiceRole .

- Sur l'écran Réviser la politique, entrez le nom de la politique, par exemple GlueConsoleAccessPolicy. Lorsque vous êtes satisfait de la politique, sélectionnez Create policy (Créer une politique). Assurez-vous qu'aucune erreur ne s'affiche dans un cadre rouge en haut de l'écran. Corrigez les erreurs signalées.

Note

Si l'option Use autoformatting est sélectionnée, la politique est reformatée chaque fois que vous ouvrez une politique ou sélectionnez Validate Policy.

Pour joindre la politique AWSGlue ConsoleFullAccess gérée

Vous pouvez joindre la AWSGlueConsoleFullAccess politique pour fournir les autorisations requises par AWS Glue utilisateur de la console.

 Note

Vous pouvez ignorer cette étape si vous avez créé votre propre politique pour AWS Glue accès à la console.

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.
2. Dans le volet de navigation, choisissez Politiques.
3. Dans la liste des politiques, cochez la case à côté de `AWSGlueConsoleFullAccess`. Vous pouvez utiliser le menu Filtre et la zone de recherche pour filtrer la liste de politiques.
4. Sélectionnez Policy Actions (Actions de politique), puis sélectionnez Attach (Attacher).
5. Sélectionnez l'utilisateur auquel attacher la politique. Vous pouvez utiliser le menu Filtre et la zone de recherche pour filtrer la liste des entités du principal. Après avoir choisi l'utilisateur auquel attacher la politique, sélectionnez Attacher la politique.

Pour attacher la politique gérée par **`AWSGlueConsoleSageMakerNotebookFullAccess`**

Vous pouvez associer la `AWSGlueConsoleSageMakerNotebookFullAccess` politique à un utilisateur pour gérer les blocs-notes SageMaker IA créés sur le AWS Glue console. En plus des autres éléments requis AWS Glue autorisations de console, cette politique donne accès aux ressources nécessaires à la gestion des blocs-notes SageMaker AI.

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.
2. Dans le volet de navigation, choisissez Politiques.
3. Dans la liste des politiques, cochez la case à côté de `AWSGlueConsoleSageMakerNotebookFullAccess`. Vous pouvez utiliser le menu Filtre et la zone de recherche pour filtrer la liste de politiques.
4. Sélectionnez Policy Actions (Actions de politique), puis sélectionnez Attach (Attacher).
5. Sélectionnez l'utilisateur auquel attacher la politique. Vous pouvez utiliser le menu Filtre et la zone de recherche pour filtrer la liste des entités du principal. Après avoir choisi l'utilisateur auquel attacher la politique, sélectionnez Attach policy (Attacher la politique).

Pour joindre la politique CloudWatchLogsReadOnlyAccess gérée

Vous pouvez associer la CloudWatchLogsReadOnlyAccesspolitique à un utilisateur pour consulter les journaux créés par AWS Glue sur la console CloudWatch Logs.

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.
2. Dans le volet de navigation, choisissez Politiques.
3. Dans la liste des politiques, cochez la case à côté de CloudWatchLogsReadOnlyAccess. Vous pouvez utiliser le menu Filtre et la zone de recherche pour filtrer la liste de politiques.
4. Sélectionnez Policy Actions (Actions de politique), puis sélectionnez Attach (Attacher).
5. Sélectionnez l'utilisateur auquel attacher la politique. Vous pouvez utiliser le menu Filtre et la zone de recherche pour filtrer la liste des entités du principal. Après avoir choisi l'utilisateur auquel attacher la politique, sélectionnez Attach policy (Attacher la politique).

Pour joindre la politique AWSCloudFormationReadOnlyAccess gérée

Vous pouvez associer la AWSCloudFormationReadOnlyAccesspolitique à un utilisateur pour afficher les AWS CloudFormation piles utilisées par AWS Glue sur la AWS CloudFormation console.

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.
2. Dans le volet de navigation, choisissez Politiques.
3. Dans la liste des politiques, cochez la case située à côté de AWSCloudFormationReadOnlyAccess. Vous pouvez utiliser le menu Filtre et la zone de recherche pour filtrer la liste de politiques.
4. Sélectionnez Policy Actions (Actions de politique), puis sélectionnez Attach (Attacher).
5. Sélectionnez l'utilisateur auquel attacher la politique. Vous pouvez utiliser le menu Filtre et la zone de recherche pour filtrer la liste des entités du principal. Après avoir choisi l'utilisateur auquel attacher la politique, sélectionnez Attach policy (Attacher la politique).

Pour joindre la politique AmazonAthenaFullAccess gérée

Vous pouvez associer la AmazonAthenaFullAccesspolitique à un utilisateur pour qu'il puisse consulter les données Amazon S3 dans la console Athena.

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.
2. Dans le volet de navigation, choisissez Politiques.
3. Dans la liste des politiques, cochez la case à côté de AmazonAthenaFullAccess. Vous pouvez utiliser le menu Filtre et la zone de recherche pour filtrer la liste de politiques.
4. Sélectionnez Policy Actions (Actions de politique), puis sélectionnez Attach (Attacher).
5. Sélectionnez l'utilisateur auquel attacher la politique. Vous pouvez utiliser le menu Filtre et la zone de recherche pour filtrer la liste des entités du principal. Après avoir choisi l'utilisateur auquel attacher la politique, sélectionnez Attach policy (Attacher la politique).

Étape 4 : créer une politique IAM pour les serveurs de blocs-notes

Si vous prévoyez d'utiliser des bloc-notes avec des points de terminaison de développement, vous devez spécifier des autorisations lorsque vous créez le serveur de bloc-notes. Vous fournissez ces autorisations à l'aide d' AWS Identity and Access Management (IAM).

Cette politique autorise certaines actions Amazon S3 visant à gérer les ressources de votre compte qui sont nécessaires pour AWS Glue lorsqu'il assume le rôle en utilisant cette politique. Certaines des ressources spécifiées dans cette politique font référence aux noms par défaut utilisés par AWS Glue pour les compartiments Amazon S3, les scripts ETL Amazon S3 et les EC2 ressources Amazon. Pour plus de simplicité, AWS Glue par défaut, l'écriture de certains objets Amazon S3 dans des compartiments de votre compte préfixés par. `aws-glue-` *

Note

Vous pouvez ignorer cette étape si vous utilisez la politique AWS gérée **AWSGlueServiceNotebookRole**.

Au cours de cette étape, vous créez une politique similaire à `AWSGlueServiceNotebookRole`. Vous pouvez consulter la version la plus récente de `AWSGlueServiceNotebookRole` sur la console IAM.

Pour créer une politique IAM pour les bloc-notes

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.

2. Dans le volet de navigation de gauche, choisissez Politiques.
3. Sélectionnez Créer une politique.
4. Sur l'écran Créer une politique, accédez à un onglet pour modifier le fichier JSON. Créez un document de politique avec les instructions JSON suivantes, puis sélectionnez Examiner une politique.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:CreateDatabase",
        "glue:CreatePartition",
        "glue:CreateTable",
        "glue>DeleteDatabase",
        "glue>DeletePartition",
        "glue>DeleteTable",
        "glue:GetDatabase",
        "glue:GetDatabases",
        "glue:GetPartition",
        "glue:GetPartitions",
        "glue:GetTable",
        "glue:GetTableVersions",
        "glue:GetTables",
        "glue:UpdateDatabase",
        "glue:UpdatePartition",
        "glue:UpdateTable",
        "glue:GetJobBookmark",
        "glue:ResetJobBookmark",
        "glue:CreateConnection",
        "glue:CreateJob",
        "glue>DeleteConnection",
        "glue>DeleteJob",
        "glue:GetConnection",
        "glue:GetConnections",
        "glue:GetDevEndpoint",
        "glue:GetDevEndpoints",
        "glue:GetJob",
        "glue:GetJobs",
        "glue:UpdateJob",
        "glue:BatchDeleteConnection",

```

```

        "glue:UpdateConnection",
        "glue:GetUserDefinedFunction",
        "glue:UpdateUserDefinedFunction",
        "glue:GetUserDefinedFunctions",
        "glue:DeleteUserDefinedFunction",
        "glue:CreateUserDefinedFunction",
        "glue:BatchGetPartition",
        "glue:BatchDeletePartition",
        "glue:BatchCreatePartition",
        "glue:BatchDeleteTable",
        "glue:UpdateDevEndpoint",
        "s3:GetBucketLocation",
        "s3:ListBucket",
        "s3:ListAllMyBuckets",
        "s3:GetBucketAcl"
    ],
    "Resource": [
        "*"
    ]
},
{
    "Effect": "Allow",
    "Action": [
        "s3:GetObject"
    ],
    "Resource": [
        "arn:aws:s3:::crawler-public*",
        "arn:aws:s3:::aws-glue*"
    ]
},
{
    "Effect": "Allow",
    "Action": [
        "s3:PutObject",
        "s3:DeleteObject"
    ],
    "Resource": [
        "arn:aws:s3:::aws-glue*"
    ]
},
{
    "Effect": "Allow",
    "Action": [
        "ec2:CreateTags",

```

```
        "ec2:DeleteTags"
      ],
      "Condition": {
        "ForAllValues:StringEquals": {
          "aws:TagKeys": [
            "aws-glue-service-resource"
          ]
        }
      },
      "Resource": [
        "arn:aws:ec2:*:*:network-interface/*",
        "arn:aws:ec2:*:*:security-group/*",
        "arn:aws:ec2:*:*:instance/*"
      ]
    }
  ]
}
```

Le tableau suivant décrit les autorisations accordées par cette politique.

Action	Ressource	Description
"glue:*"	"*"	Accorde l'autorisation de tout exécuter AWS Glue Opérations d'API.
"s3:GetBucketLocat ion", "s3:ListB ucket", "s3:ListA llMyBuckets", "s3:GetBucketAcl"	"*"	Permet de répertorier les compartiments Amazon S3 à partir des serveurs de bloc-notes.

Action	Ressource	Description
"s3:GetObject"	"arn:aws:s3:::crawler-public*", "arn:aws:s3:::aws-glue-*"	Permet d'obtenir des objets Amazon S3 utilisés par des exemples et des didacticiels de bloc-notes. Convention de dénomination : les noms de compartiments Amazon S3 dont le nom commence par crawler-public et aws-glue-.
"s3:PutObject", "s3:DeleteObject"	"arn:aws:s3:::aws-glue*"	Permet d'ajouter et de supprimer des objets Amazon S3 dans votre compte à partir des bloc-notes. Convention de dénomination : utilise les dossiers Amazon S3 nommés aws-glue-.
"ec2:CreateTags", "ec2:DeleteTags"	"arn:aws:ec2:*:*:network-interface/*", "arn:aws:ec2:*:*:security-group/*", "arn:aws:ec2:*:*:instance/*"	Permet de baliser les EC2 ressources Amazon créées pour les serveurs d'ordinateurs portables. Convention de dénomination : AWS Glue étiquette les EC2 instances Amazon avec aws-glue-service-resource.

5. Sur l'écran Review policy (Examiner la politique), saisissez votre Policy Name (Nom de politique), par exemple, GlueServiceNotebookPolicyDefault. Saisissez éventuellement une description, et lorsque vous êtes satisfait de la politique, sélectionnez Créer une politique.

Étape 5 : créer un rôle IAM pour les serveurs de blocs-notes

Si vous prévoyez d'utiliser des bloc-notes avec des points de terminaison de développement, vous devez accorder les autorisations de rôles IAM. Vous fournissez ces autorisations en utilisant AWS Identity and Access Management IAM, via un rôle IAM.

Note

Lorsque vous créez un rôle IAM à l'aide de la console IAM, celle-ci crée automatiquement un profil d'instance et lui attribue le même nom qu'au rôle auquel il correspond.

Pour créer un rôle IAM pour des bloc-notes

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.
2. Dans le volet de navigation de gauche, choisissez Rôles.
3. Choisissez Créer un rôle.
4. Pour le type de rôle, choisissez AWS Service, recherchez et choisissez EC2, puis choisissez le cas EC2 d'utilisation, puis choisissez Suivant : Autorisations.
5. Sur la page Joindre une politique d'autorisations, choisissez les politiques qui contiennent les autorisations requises ; par exemple, AWSGlueServiceNotebookRole pour les règles générales AWS Glue les autorisations et la politique AWS gérée AmazonS3 FullAccess pour l'accès aux ressources Amazon S3. Choisissez ensuite Next: Review.

Note

Assurez-vous que l'une des politiques de ce rôle accorde des autorisations à vos sources et cibles Amazon S3. Confirmez également que votre politique autorise un accès complet à l'emplacement dans lequel vous stockez votre bloc-notes lors de la création d'un serveur de bloc-notes. Vous pouvez vouloir fournir votre propre politique pour l'accès à certaines ressources Amazon S3. Pour plus d'informations sur la création

d'une politique Amazon S3 pour vos ressources, consultez [Spécification des ressources d'une politique](#).

Si vous prévoyez d'accéder à des sources et cibles Amazon S3 chiffrées avec SSE-KMS, attachez une politique permettant aux bloc-notes de déchiffrer les données. Pour plus d'informations, voir [Protection des données à l'aide du chiffrement côté serveur avec des clés AWS KMS gérées \(SSE-KMS\)](#).

Voici un exemple.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "kms:Decrypt"
      ],
      "Resource": [
        "arn:aws:kms:*:account-id-without-hyphens:key/key-id"
      ]
    }
  ]
}
```

6. Dans le champ Role name (Nom de rôle), saisissez un nom pour votre rôle. Créez le rôle avec le nom préfixé par la chaîne `AWSGlueServiceNotebookRole` pour permettre au rôle d'être transmis des utilisateurs de console au serveur de blocs-notes. AWS Glue les politiques fournies prévoient que les rôles de service IAM doivent commencer `AWSGlueServiceNotebookRole` par. Sinon, vous devez ajouter une politique à vos utilisateurs accordant l'autorisation `iam:PassRole` aux rôles IAM de correspondre à votre convention de dénomination. Par exemple, saisissez `AWSGlueServiceNotebookRoleDefault`. Puis choisissez `Create role` (Créer un rôle).

Étape 6 : créer une politique IAM pour les ordinateurs portables dotés d' SageMaker intelligence artificielle

Si vous envisagez d'utiliser des blocs-notes SageMaker AI avec des terminaux de développement, vous devez spécifier des autorisations lors de la création du bloc-notes. Vous fournissez ces autorisations à l'aide d' AWS Identity and Access Management (IAM).

Pour créer une politique IAM pour les ordinateurs portables dotés d' SageMaker intelligence artificielle

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.
2. Dans le volet de navigation de gauche, choisissez Politiques.
3. Sélectionnez Créer une politique.
4. Sur la page Créer une politique, accédez à un onglet pour modifier le fichier JSON. Créez votre document de politique avec les instructions JSON suivantes. Modifiez *bucket-name**region-code*, et *account-id* pour votre environnement.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Action": [
        "s3:ListBucket"
      ],
      "Effect": "Allow",
      "Resource": [
        "arn:aws:s3:::bucket-name"
      ]
    },
    {
      "Action": [
        "s3:GetObject"
      ],
      "Effect": "Allow",
      "Resource": [
        "arn:aws:s3:::bucket-name*"
      ]
    },
    {
      "Action": [
        "logs:CreateLogStream",
        "logs:DescribeLogStreams",
        "logs:PutLogEvents",
        "logs:CreateLogGroup"
      ],
      "Effect": "Allow",
      "Resource": [
```

```
        "arn:aws:logs:region-code:account-id:log-group:/aws/sagemaker/*",
        "arn:aws:logs:region-code:account-id:log-group:/aws/sagemaker/
*:log-stream:aws-glue-*"
    ],
    },
    {
        "Action": [
            "glue:UpdateDevEndpoint",
            "glue:GetDevEndpoint",
            "glue:GetDevEndpoints"
        ],
        "Effect": "Allow",
        "Resource": [
            "arn:aws:glue:region-code:account-id:devEndpoint/*"
        ]
    },
    {
        "Action": [
            "sagemaker:ListTags"
        ],
        "Effect": "Allow",
        "Resource": [
            "arn:aws:sagemaker:region-code:account-id:notebook-instance/*"
        ]
    }
  ]
}
```

Sélectionnez ensuite Examiner une politique.

Le tableau suivant décrit les autorisations accordées par cette politique.

Action	Ressource	Description
"s3:ListBucket"	"arn:aws:s3::: bucket-name "	Octroie l'autorisation de répertorier les compartiments Amazon S3.

Action	Ressource	Description
"s3:GetObject"	"arn:aws:s3::: <i>bucket-name</i> *"	Accorde l'autorisation d'obtenir des objets Amazon S3 utilisés par les blocs-notes dotés d' SageMaker intelligence artificielle.
"logs:CreateLogStream", "logs:DescribeLogStreams", "logs:PutLogEvents", "logs:CreateLogGroup"	"arn:aws:logs: <i>region-code</i> : <i>account-id</i> :log-group:/aws/sagemaker/*", "arn:aws:logs: <i>region-code</i> : <i>account-id</i> :log-group:/aws/sagemaker/*:log-stream:aws-glue-*"	Accorde l'autorisation d'écrire des CloudWatch journaux sur Amazon Logs à partir de carnets de notes. Convention de dénomination : écrit dans les groupes de journaux dont le nom commence par aws-glue.
"glue:UpdateDevEndpoint", "glue:GetDevEndpoint", "glue:GetDevEndpoints"	"arn:aws:glue: <i>region-code</i> : <i>account-id</i> :devEndpoint/*"	Accorde l'autorisation d'utiliser un point de développement à partir de blocs-notes d' SageMaker IA.
"sagemaker:ListTags"	"arn:aws:sagemaker : <i>region-code</i> : <i>account-id</i> :notebook-instance/*"	Accorde l'autorisation de renvoyer des balises pour une ressource d' SageMaker IA. La aws-glue-dev-endpoint balise est requise sur le bloc-notes SageMaker AI pour connecter le bloc-notes à un terminal de développement.

- Sur l'écran Review policy (Examiner la politique), saisissez votre Policy Name (Nom de politique), par exemple, AWSGlueSageMakerNotebook. Saisissez éventuellement une description, et lorsque vous êtes satisfait de la politique, sélectionnez Créer une politique.

Étape 7 : créer un rôle IAM pour les blocs-notes SageMaker AI

Si vous envisagez d'utiliser des blocs-notes SageMaker AI avec des points de terminaison de développement, vous devez accorder des autorisations au rôle IAM. Vous fournissez ces autorisations en utilisant AWS Identity and Access Management (IAM), via un rôle IAM.

Pour créer un rôle IAM pour les blocs-notes SageMaker AI

1. Connectez-vous à la console IAM AWS Management Console et ouvrez-la à <https://console.aws.amazon.com/iam/> l'adresse.
2. Dans le volet de navigation de gauche, choisissez Rôles.
3. Choisissez Créer un rôle.
4. Pour le type de rôle, choisissez AWS Service, recherchez et choisissez SageMaker, puis choisissez le cas d'utilisation SageMaker - Exécution. Choisissez ensuite Suivant : Autorisations.
5. Sur la page Joindre une politique d'autorisations, choisissez les politiques contenant les autorisations requises ; par exemple, AmazonSageMakerFullAccess. Choisissez Suivant : Vérification.

Si vous prévoyez d'accéder à des sources et cibles Amazon S3 qui sont chiffrées avec SSE-KMS, vous devrez attacher une politique permettant aux blocs-notes de déchiffrer les données, comme illustré dans l'exemple suivant. Pour plus d'informations, voir [Protection des données à l'aide du chiffrement côté serveur avec des clés AWS KMS gérées \(SSE-KMS\)](#).

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "kms:Decrypt"
      ],
      "Resource": [
        "arn:aws:kms:*:account-id-without-hyphens:key/key-id"
      ]
    }
  ]
}
```

6. Dans le champ Role name (Nom de rôle), saisissez un nom pour votre rôle. Pour autoriser le transfert du rôle des utilisateurs de la console à l' SageMaker IA, utilisez un nom préfixé par la

chaîne `AWSGlueServiceSageMakerNotebookRole`. AWS Glue à condition que les politiques prévoient que les rôles IAM commencent `AWSGlueServiceSageMakerNotebookRole` par. Sinon, vous devez ajouter une politique à vos utilisateurs accordant l'autorisation `iam:PassRole` aux rôles IAM de correspondre à votre convention de dénomination.

Par exemple, saisissez `AWSGlueServiceSageMakerNotebookRole-Default`, puis sélectionnez `Create role` (Créer le rôle).

7. Après avoir créé le rôle, joignez la politique qui autorise les autorisations supplémentaires requises pour créer des blocs-notes SageMaker AI à partir de AWS Glue.

Ouvrez le rôle que vous venez de créer, `AWSGlueServiceSageMakerNotebookRole-Default`, puis sélectionnez `Attach policies` (Attacher des politiques). Attachez la politique nommée `AWSGlueSageMakerNotebook` que vous avez créée au rôle.

AWS Exemples de politiques de contrôle d'accès Glue

Cette section contient des exemples de politiques de contrôle d'accès basées sur l'identité (IAM) et AWS Glue politiques en matière de ressources.

Table des matières

- [Exemples de politiques basées sur l'identité pour Glue AWS](#)
 - [Bonnes pratiques en matière de politiques](#)
 - [Les autorisations au niveau des ressources ne s'appliquent qu'à des AWS Glue objects](#)
 - [Utilisation de la console AWS Glue](#)
 - [Autorisation accordée aux utilisateurs pour afficher leurs propres autorisations](#)
 - [Octroyer une autorisation en lecture seule à une table](#)
 - [Filtrer les tables par `GetTables` autorisation](#)
 - [Octroyer un accès complet à une table et à toutes les partitions](#)
 - [Contrôler l'accès par préfixe du nom et refus explicite](#)
 - [Octoyer l'accès à l'aide de balises](#)
 - [Refuser l'accès à l'aide de balises](#)
 - [Utiliser des balises avec les opérations d'API de liste et de lot](#)
 - [Contrôler les paramètres à l'aide de clés de condition ou de contexte](#)
 - [Contrôler les politiques qui contrôlent les paramètres à l'aide des clés de condition](#)

- [Contrôler des politiques qui contrôlent les paramètres à l'aide des clés de contexte](#)
- [Refus de la possibilité de créer des sessions d'aperçu des données à une identité](#)
- [Exemples de politiques basées sur les ressources pour Glue AWS](#)
- [Considérations relatives à l'utilisation de politiques basées sur les ressources avec Glue AWS](#)
- [Utiliser une politique de ressource pour contrôler l'accès dans le même compte](#)

Exemples de politiques basées sur l'identité pour Glue AWS

Par défaut, les utilisateurs et les rôles ne sont pas autorisés à créer ou à modifier les ressources AWS Glue. Ils ne peuvent pas non plus effectuer de tâches à l'aide de l'API AWS Management Console, AWS Command Line Interface (AWS CLI) ou de AWS l'API. Pour octroyer aux utilisateurs des autorisations d'effectuer des actions sur les ressources dont ils ont besoin, un administrateur IAM peut créer des politiques IAM. L'administrateur peut ensuite ajouter les politiques IAM aux rôles et les utilisateurs peuvent assumer les rôles.

Pour apprendre à créer une politique basée sur l'identité IAM à l'aide de ces exemples de documents de politique JSON, consultez [Création de politiques IAM \(console\)](#) dans le Guide de l'utilisateur IAM.

Pour plus de détails sur les actions et les types de ressources définis par AWS Glue, y compris le ARNs format de chaque type de ressource, voir [Actions, ressources et clés de condition pour AWS Glue](#) dans le Service Authorization Reference.

Note

Les exemples fournis dans cette section utilisent tous la région us-west-2. Vous pouvez le remplacer par la AWS région que vous souhaitez utiliser.

Rubriques

- [Bonnes pratiques en matière de politiques](#)
- [Les autorisations au niveau des ressources ne s'appliquent qu'à des AWS Glue objects](#)
- [Utilisation de la console AWS Glue](#)
- [Autorisation accordée aux utilisateurs pour afficher leurs propres autorisations](#)
- [Octroyer une autorisation en lecture seule à une table](#)
- [Filtrer les tables par GetTables autorisation](#)

- [Octroyer un accès complet à une table et à toutes les partitions](#)
- [Contrôler l'accès par préfixe du nom et refus explicite](#)
- [Octoyer l'accès à l'aide de balises](#)
- [Refuser l'accès à l'aide de balises](#)
- [Utiliser des balises avec les opérations d'API de liste et de lot](#)
- [Contrôler les paramètres à l'aide de clés de condition ou de contexte](#)
- [Refus de la possibilité de créer des sessions d'aperçu des données à une identité](#)

Bonnes pratiques en matière de politiques

Les politiques basées sur l'identité déterminent si quelqu'un peut créer, accéder ou supprimer les ressources AWS Glue de votre compte. Ces actions peuvent entraîner des frais pour votre Compte AWS. Lorsque vous créez ou modifiez des politiques basées sur l'identité, suivez ces instructions et recommandations :

- Commencez AWS par les politiques gérées et passez aux autorisations du moindre privilège : pour commencer à accorder des autorisations à vos utilisateurs et à vos charges de travail, utilisez les politiques AWS gérées qui accordent des autorisations pour de nombreux cas d'utilisation courants. Ils sont disponibles dans votre Compte AWS. Nous vous recommandons de réduire davantage les autorisations en définissant des politiques gérées par les AWS clients spécifiques à vos cas d'utilisation. Pour plus d'informations, consultez [politiques gérées par AWS](#) ou [politiques gérées par AWS pour les activités professionnelles](#) dans le Guide de l'utilisateur IAM.
- Accordez les autorisations de moindre privilège : lorsque vous définissez des autorisations avec des politiques IAM, accordez uniquement les autorisations nécessaires à l'exécution d'une seule tâche. Pour ce faire, vous définissez les actions qui peuvent être entreprises sur des ressources spécifiques dans des conditions spécifiques, également appelées autorisations de moindre privilège. Pour plus d'informations sur l'utilisation d'IAM pour appliquer des autorisations, consultez [politiques et autorisations dans IAM](#) dans le Guide de l'utilisateur IAM.
- Utilisez des conditions dans les politiques IAM pour restreindre davantage l'accès : vous pouvez ajouter une condition à vos politiques afin de limiter l'accès aux actions et aux ressources. Par exemple, vous pouvez écrire une condition de politique pour spécifier que toutes les demandes doivent être envoyées via SSL. Vous pouvez également utiliser des conditions pour accorder l'accès aux actions de service si elles sont utilisées par le biais d'un service spécifique Service AWS, tel que AWS CloudFormation. Pour plus d'informations, consultez [Conditions pour éléments de politique JSON IAM](#) dans le Guide de l'utilisateur IAM.

- Utilisez l'Analyseur d'accès IAM pour valider vos politiques IAM afin de garantir des autorisations sécurisées et fonctionnelles : l'Analyseur d'accès IAM valide les politiques nouvelles et existantes de manière à ce que les politiques IAM respectent le langage de politique IAM (JSON) et les bonnes pratiques IAM. IAM Access Analyzer fournit plus de 100 vérifications de politiques et des recommandations exploitables pour vous aider à créer des politiques sécurisées et fonctionnelles. Pour plus d'informations, consultez [Validation de politiques avec IAM Access Analyzer](#) dans le Guide de l'utilisateur IAM.
- Exiger l'authentification multifactorielle (MFA) : si vous avez un scénario qui nécessite des utilisateurs IAM ou un utilisateur root, activez l'authentification MFA pour une sécurité accrue. Compte AWS Pour exiger la MFA lorsque des opérations d'API sont appelées, ajoutez des conditions MFA à vos politiques. Pour plus d'informations, consultez [Sécurisation de l'accès aux API avec MFA](#) dans le Guide de l'utilisateur IAM.

Pour plus d'informations sur les bonnes pratiques dans IAM, consultez [Bonnes pratiques de sécurité dans IAM](#) dans le Guide de l'utilisateur IAM.

Les autorisations au niveau des ressources ne s'appliquent qu'à des AWS Glue objects

Vous ne pouvez définir un contrôle précis que pour des objets spécifiques dans AWS Glue. Vous devez donc écrire la politique IAM de votre client afin que les opérations d'API qui autorisent Amazon Resource Names (ARNs) pour l'ResourceInstruction ne soient pas mélangées avec les opérations d'API qui ne l'autorisent pas.

Par exemple, la politique IAM suivante autorise les opérations d'API pour GetClassifier et GetJobRun. Il définit le Resource comme étant le * fait que AWS Glue n'autorise pas ARNs les classificateurs et les exécutions de tâches. Parce que ARNs sont autorisées pour des opérations d'API spécifiques telles que GetDatabase et GetTable, ARNs peuvent être spécifiées dans la seconde moitié de la politique.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:GetClassifier*",
        "glue:GetJobRun*"
      ],
      "Resource": "*"
    }
  ]
}
```

```
    },
    {
      "Effect": "Allow",
      "Action": [
        "glue:Get*"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:123456789012:catalog",
        "arn:aws:glue:us-east-1:123456789012:database/default",
        "arn:aws:glue:us-east-1:123456789012:table/default/e*1*",
        "arn:aws:glue:us-east-1:123456789012:connection/connection2"
      ]
    }
  ]
}
```

Pour une liste des AWS Glue objets qui le permettent ARNs, voir [Spécification AWS Glue Ressource ARNs](#).

Utilisation de la console AWS Glue

Pour accéder à la console AWS Glue, vous devez disposer d'un minimum d'autorisations. Ces autorisations doivent vous permettre de répertorier et de consulter les détails des ressources AWS Glue de votre Compte AWS. Si vous créez une politique basée sur l'identité qui est plus restrictive que l'ensemble minimum d'autorisations requis, la console ne fonctionnera pas comme prévu pour les entités (utilisateurs ou rôles) tributaires de cette politique.

Il n'est pas nécessaire d'accorder des autorisations de console minimales aux utilisateurs qui appellent uniquement l'API AWS CLI ou l' AWS API. Autorisez plutôt l'accès à uniquement aux actions qui correspondent à l'opération d'API qu'ils tentent d'effectuer.

Pour garantir que les utilisateurs et les rôles peuvent toujours utiliser la console AWS Glue, associez également la AWS Glue *ConsoleAccess* ou la politique *ReadOnly* AWS gérée aux entités. Pour plus d'informations, consultez [Ajout d'autorisations à un utilisateur](#) dans le Guide de l'utilisateur IAM.

Pour qu'un utilisateur puisse travailler avec AWS Glue console, cet utilisateur doit disposer d'un ensemble minimal d'autorisations lui permettant de travailler avec AWS Glue ressources pour leur AWS compte. En plus de ceux-ci AWS Glue autorisations, la console a besoin des autorisations des services suivants :

- Autorisations Amazon CloudWatch Logs pour afficher les journaux.

- AWS Identity and Access Management (IAM) autorisations permettant de répertorier et de transmettre des rôles.
- AWS CloudFormation autorisations pour travailler avec des piles.
- Autorisations Amazon Elastic Compute Cloud (Amazon EC2) permettant de VPCs répertorier des sous-réseaux, des groupes de sécurité, des instances et d'autres objets.
- Autorisations Amazon Simple Storage Service (Amazon S3) pour répertorier les compartiments et les objets, et pour récupérer et enregistrer les scripts.
- Autorisations Amazon Redshift requises pour travailler avec des clusters.
- Autorisations Amazon Relational Database Service (Amazon RDS) pour répertorier les instances.

Pour plus d'informations sur les autorisations dont les utilisateurs ont besoin pour consulter et utiliser AWS Glue console, voir [Étape 3 : associer une politique aux utilisateurs ou aux groupes qui accèdent AWS Glue](#).

Si vous créez une politique IAM plus restrictive que les autorisations minimales requises, la console ne fonctionnera pas comme prévu pour les utilisateurs dotés de cette politique IAM. Pour s'assurer que ces utilisateurs peuvent toujours utiliser le AWS Glue console, attachez également la politique `AWSGlueConsoleFullAccess` gérée comme décrit dans [AWS politiques gérées \(prédéfinies\) pour AWS Glue](#).

Autorisation accordée aux utilisateurs pour afficher leurs propres autorisations

Cet exemple montre comment créer une politique qui permet aux utilisateurs IAM d'afficher les politiques en ligne et gérées attachées à leur identité d'utilisateur. Cette politique inclut les autorisations permettant d'effectuer cette action sur la console ou par programmation à l'aide de l'API AWS CLI or AWS .

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "ViewOwnUserInfo",
      "Effect": "Allow",
      "Action": [
        "iam:GetUserPolicy",
        "iam:ListGroupsForUser",
        "iam:ListAttachedUserPolicies",
        "iam:ListUserPolicies",
        "iam:GetUser"
      ]
    }
  ]
}
```

```

    ],
    "Resource": ["arn:aws:iam::*:user/${aws:username}"]
  },
  {
    "Sid": "NavigateInConsole",
    "Effect": "Allow",
    "Action": [
      "iam:GetGroupPolicy",
      "iam:GetPolicyVersion",
      "iam:GetPolicy",
      "iam:ListAttachedGroupPolicies",
      "iam:ListGroupPolicies",
      "iam:ListPolicyVersions",
      "iam:ListPolicies",
      "iam:ListUsers"
    ],
    "Resource": "*"
  }
]
}

```

Octroyer une autorisation en lecture seule à une table

La politique suivante accorde une autorisation en lecture seule à une table nommée books dans la base de données nommée db1. Pour plus d'informations sur la ressource Amazon Resource Names (ARNs), consultez [Catalogue de données ARNs](#).

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "GetTablesActionOnBooks",
      "Effect": "Allow",
      "Action": [
        "glue:GetTables",
        "glue:GetTable"
      ],
      "Resource": [
        "arn:aws:glue:us-west-2:123456789012:catalog",
        "arn:aws:glue:us-west-2:123456789012:database/db1",
        "arn:aws:glue:us-west-2:123456789012:table/db1/books"
      ]
    }
  ]
}

```

```
]
}
```

Cette politique accorde l'autorisation en lecture seule à une table nommée `books` dans la base de données nommée `db1`. Pour accorder une autorisation `Get` à une table, cette autorisation est également requise pour le catalogue et les ressources de base de données.

La politique suivante accorde les autorisations nécessaires minimales pour créer la table `tb1` dans la base de données `db1` :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:CreateTable"
      ],
      "Resource": [
        "arn:aws:glue:us-west-2:123456789012:table/db1/tb1",
        "arn:aws:glue:us-west-2:123456789012:database/db1",
        "arn:aws:glue:us-west-2:123456789012:catalog"
      ]
    }
  ]
}
```

Filtrer les tables par `GetTables` autorisation

Supposons qu'il y ait trois tables, `customers`, `stores` et `store_sales` dans la base de données `db1`. La politique suivante octroie l'autorisation `GetTables` à `stores` et `store_sales`, mais pas à `customers`. Lorsque vous appelez `GetTables` avec cette politique, le résultat contient uniquement les deux tables autorisées (la table `customers` n'est pas renvoyée).

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "GetTablesExample",
      "Effect": "Allow",
      "Action": [
        "glue:GetTables"
      ]
    }
  ]
}
```

```

    ],
    "Resource": [
        "arn:aws:glue:us-west-2:123456789012:catalog",
        "arn:aws:glue:us-west-2:123456789012:database/db1",
        "arn:aws:glue:us-west-2:123456789012:table/db1/store_sales",
        "arn:aws:glue:us-west-2:123456789012:table/db1/stores"
    ]
}

```

Vous pouvez simplifier la politique précédente en utilisant `store*` pour correspondre à tous les noms de table qui commencent par `store`.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "GetTablesExample2",
      "Effect": "Allow",
      "Action": [
        "glue:GetTables"
      ],
      "Resource": [
        "arn:aws:glue:us-west-2:123456789012:catalog",
        "arn:aws:glue:us-west-2:123456789012:database/db1",
        "arn:aws:glue:us-west-2:123456789012:table/db1/store*"
      ]
    }
  ]
}

```

De même, si vous utilisez `/db1/*` pour une correspondance avec toutes les tables `db1`, la politique suivante accorde l'accès `GetTables` à toutes les tables de `db1`.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "GetTablesReturnAll",
      "Effect": "Allow",
      "Action": [

```



```

        "glue:GetTables"
    ],
    "Resource": [
        "arn:aws:glue:us-west-2:123456789012:catalog",
        "arn:aws:glue:us-west-2:123456789012:database/db1",
        "arn:aws:glue:us-west-2:123456789012:table/db1/*"
    ]
}

```

Si aucun ARN de table n'est fourni, un appel de `GetTables` réussit, mais renvoie une liste vide.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "GetTablesEmptyResults",
      "Effect": "Allow",
      "Action": [
        "glue:GetTables"
      ],
      "Resource": [
        "arn:aws:glue:us-west-2:123456789012:catalog",
        "arn:aws:glue:us-west-2:123456789012:database/db1"
      ]
    }
  ]
}

```

Si l'ARN de la base de données est manquant dans la politique, un appel à `GetTables` échoue avec une `erreurAccessDeniedException`.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "GetTablesAccessDeny",
      "Effect": "Allow",
      "Action": [
        "glue:GetTables"
      ],
      "Resource": [

```

```

        "arn:aws:glue:us-west-2:123456789012:catalog",
        "arn:aws:glue:us-west-2:123456789012:table/db1/*"
    ]
}

```

Octroyer un accès complet à une table et à toutes les partitions

La politique suivante accorde toutes les autorisations sur une table nommée books dans la base de données db1. Cela inclut les autorisations de lecture et d'écriture sur la table elle-même, sur les versions archivées et sur toutes ses partitions.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "FullAccessOnTable",
      "Effect": "Allow",
      "Action": [
        "glue:CreateTable",
        "glue:GetTable",
        "glue:GetTables",
        "glue:UpdateTable",
        "glue>DeleteTable",
        "glue:BatchDeleteTable",
        "glue:GetTableVersion",
        "glue:GetTableVersions",
        "glue>DeleteTableVersion",
        "glue:BatchDeleteTableVersion",
        "glue:CreatePartition",
        "glue:BatchCreatePartition",
        "glue:GetPartition",
        "glue:GetPartitions",
        "glue:BatchGetPartition",
        "glue:UpdatePartition",
        "glue>DeletePartition",
        "glue:BatchDeletePartition"
      ],
      "Resource": [
        "arn:aws:glue:us-west-2:123456789012:catalog",
        "arn:aws:glue:us-west-2:123456789012:database/db1",
        "arn:aws:glue:us-west-2:123456789012:table/db1/books"
      ]
    }
  ]
}

```

```

    ]
  }
}

```

La politique précédente peut être simplifiée dans la pratique.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "FullAccessOnTable",
      "Effect": "Allow",
      "Action": [
        "glue:*Table*",
        "glue:*Partition*"
      ],
      "Resource": [
        "arn:aws:glue:us-west-2:123456789012:catalog",
        "arn:aws:glue:us-west-2:123456789012:database/db1",
        "arn:aws:glue:us-west-2:123456789012:table/db1/books"
      ]
    }
  ]
}

```

Notez que la granularité minimum d'un contrôle d'accès précis se trouve au niveau de la table. Cela signifie que vous ne pouvez pas accorder à un utilisateur l'accès à certaines partitions dans une table, mais pas à d'autres, ou à certaines colonnes de la table, mais pas à d'autres. Un utilisateur a soit accès à toute la table, soit à aucune partie de la table.

Contrôler l'accès par préfixe du nom et refus explicite

Dans cet exemple, supposons que les bases de données et les tables de votre AWS Glue Data Catalog soient organisées à l'aide de préfixes de nom. Les bases de données à l'étape de développement ont le préfixe de nom `dev-` et celles en production ont le préfixe de nom `prod-`. Vous pouvez utiliser la politique suivante pour accorder aux développeurs un accès complet à toutes les bases de données UDFs, tables, etc., qui portent le `dev-` préfixe. Mais vous accordez un accès en lecture seule à tout avec le préfixe `prod-`.

```

{
  "Version": "2012-10-17",

```

```

"Statement": [
  {
    "Sid": "DevAndProdFullAccess",
    "Effect": "Allow",
    "Action": [
      "glue:*Database*",
      "glue:*Table*",
      "glue:*Partition*",
      "glue:*UserDefinedFunction*",
      "glue:*Connection*"
    ],
    "Resource": [
      "arn:aws:glue:us-west-2:123456789012:catalog",
      "arn:aws:glue:us-west-2:123456789012:database/dev-*",
      "arn:aws:glue:us-west-2:123456789012:database/prod-*",
      "arn:aws:glue:us-west-2:123456789012:table/dev-*/*",
      "arn:aws:glue:us-west-2:123456789012:table/*/dev-*",
      "arn:aws:glue:us-west-2:123456789012:table/prod-*/*",
      "arn:aws:glue:us-west-2:123456789012:table/*/prod-*",
      "arn:aws:glue:us-west-2:123456789012:userDefinedFunction/dev-*/*",
      "arn:aws:glue:us-west-2:123456789012:userDefinedFunction/*/dev-*",
      "arn:aws:glue:us-west-2:123456789012:userDefinedFunction/prod-*/*",
      "arn:aws:glue:us-west-2:123456789012:userDefinedFunction/*/prod-*",
      "arn:aws:glue:us-west-2:123456789012:connection/dev-*",
      "arn:aws:glue:us-west-2:123456789012:connection/prod-*"
    ]
  },
  {
    "Sid": "ProdWriteDeny",
    "Effect": "Deny",
    "Action": [
      "glue:*Create*",
      "glue:*Update*",
      "glue:*Delete*"
    ],
    "Resource": [
      "arn:aws:glue:us-west-2:123456789012:database/prod-*",
      "arn:aws:glue:us-west-2:123456789012:table/prod-*/*",
      "arn:aws:glue:us-west-2:123456789012:table/*/prod-*",
      "arn:aws:glue:us-west-2:123456789012:userDefinedFunction/prod-*/*",
      "arn:aws:glue:us-west-2:123456789012:userDefinedFunction/*/prod-*",
      "arn:aws:glue:us-west-2:123456789012:connection/prod-*"
    ]
  }
]

```

```
]
}
```

La deuxième instruction de la politique précédente utilise le explicite deny. Vous pouvez utiliser le deny explicite pour remplacer toutes les autorisations allow qui sont accordées au principal. Cela vous permet de verrouiller l'accès aux ressources critiques et d'éviter qu'une autre politique accorde un accès à celles-ci par accident.

Dans l'exemple précédent, même si la première instruction accorde un accès complet aux ressources prod-, la deuxième instruction révoque explicitement l'accès en écriture à celles-ci, laissant uniquement l'accès en lecture aux ressources prod-.

Octoyer l'accès à l'aide de balises

Par exemple, supposons que vous souhaitiez limiter l'accès à un déclencheur t2 à un utilisateur spécifique nommé Tom dans votre compte. Tous les autres utilisateurs, y compris Sam, ont accès au déclencheur t1. Les déclencheurs t1 et t2 ont les propriétés suivantes.

```
aws glue get-triggers
{
  "Triggers": [
    {
      "State": "CREATED",
      "Type": "SCHEDULED",
      "Name": "t1",
      "Actions": [
        {
          "JobName": "j1"
        }
      ],
      "Schedule": "cron(0 0/1 * * ? *)"
    },
    {
      "State": "CREATED",
      "Type": "SCHEDULED",
      "Name": "t2",
      "Actions": [
        {
          "JobName": "j1"
        }
      ],
      "Schedule": "cron(0 0/1 * * ? *)"
    }
  ]
}
```

```

    }
  ]
}
```

Le AWS Glue l'administrateur a attaché une valeur de balise Tom (`aws:ResourceTag/Name` : "Tom") au déclencheur t2. Le AWS Glue L'administrateur a également donné à Tom une politique IAM avec une déclaration de condition basée sur le tag. Par conséquent, Tom ne peut utiliser qu'un AWS Glue opération qui agit sur les ressources avec la valeur du tag Tom.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "glue:*",
      "Resource": "*",
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/Name": "Tom"
        }
      }
    }
  ]
}
```

Lorsque Tom essaie d'accéder au déclencheur t1, il reçoit un message d'accès refusé. Dans le même temps, il parvient à récupérer le déclencheur t2.

```
aws glue get-trigger --name t1
```

An error occurred (AccessDeniedException) when calling the GetTrigger operation:

User: Tom is not authorized to perform: glue:GetTrigger on resource: arn:aws:glue:us-east-1:123456789012:trigger/t1

```
aws glue get-trigger --name t2
```

```

{
  "Trigger": {
    "State": "CREATED",
    "Type": "SCHEDULED",
    "Name": "t2",
    "Actions": [
      {
```

```

        "JobName": "j1"
      }
    ],
    "Schedule": "cron(0 0/1 * * ? *)"
  }
}

```

Tom ne peut pas utiliser l'opération d'API plurielle `GetTriggers` pour répertorier les déclencheurs, car celle-ci ne prend pas en charge le filtrage des balises.

Pour permettre à Tom d'accéder à `GetTriggers`, AWS Glue L'administrateur crée une politique qui divise les autorisations en deux sections. Une section autorise Tom à accéder à tous les déclencheurs avec l'opération d'API `GetTriggers`. La deuxième section autorise Tom à accéder aux opérations d'API qui sont balisées avec la valeur Tom. Avec cette politique, Tom est autorisé à accéder à la fois à `GetTriggers` et à `GetTrigger` pour déclencher t2.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "glue:GetTriggers",
      "Resource": "*"
    },
    {
      "Effect": "Allow",
      "Action": "glue:*",
      "Resource": "*",
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/Name": "Tom"
        }
      }
    }
  ]
}

```

Refuser l'accès à l'aide de balises

Une autre approche de politique de ressource consiste à refuser explicitement l'accès aux ressources.

⚠ Important

Une politique de refus explicite ne fonctionne pas pour les opérations d'API plurielles telles que `GetTriggers`.

Dans l'exemple de politique suivant, toutes AWS Glue les opérations de travail sont autorisées. Cependant, la deuxième instruction `Effect` refuse explicitement l'accès aux tâches balisées avec la clé `Team` et la valeur `Special`.

Lorsqu'un administrateur attache la politique suivante à une identité, cette dernière peut accéder à toutes les tâches, sauf celles balisées avec la clé `Team` et la valeur `Special`.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "glue:*",
      "Resource": "arn:aws:glue:us-east-1:123456789012:job/*"
    },
    {
      "Effect": "Deny",
      "Action": "glue:*",
      "Resource": "arn:aws:glue:us-east-1:123456789012:job/*",
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/Team": "Special"
        }
      }
    }
  ]
}
```

Utiliser des balises avec les opérations d'API de liste et de lot

Une troisième approche possible pour écrire une politique de ressource consiste à autoriser l'accès aux ressources à l'aide d'une opération d'API `List` pour répertorier les ressources pour une valeur de balise. Ensuite, utilisez l'opération d'API `Batch` correspondante pour autoriser l'accès aux détails des ressources spécifiques. Avec cette approche, l'administrateur n'a pas besoin d'autoriser l'accès aux opérations d'API `GetCrawlers`, `GetDevEndpoints`, `GetJobs` ou `GetTriggers` plurielles.

Au lieu de cela, vous pouvez permettre de répertorier les ressources avec les opérations d'API suivantes :

- `ListCrawlers`
- `ListDevEndpoints`
- `ListJobs`
- `ListTriggers`

De plus, vous pouvez permettre d'obtenir des détails sur les ressources individuelles avec les opérations d'API suivantes :

- `BatchGetCrawlers`
- `BatchGetDevEndpoints`
- `BatchGetJobs`
- `BatchGetTriggers`

En tant qu'administrateur, pour utiliser cette approche, vous pouvez effectuer les opérations suivantes :

1. Ajouter des balises à vos crawlers, points de terminaison de développement, tâches et déclencheurs.
2. Refuser l'accès utilisateur aux opérations d'API Get telles que `GetCrawlers`, `GetDevEndpoints`, `GetJobs` et `GetTriggers`.
3. Pour permettre aux utilisateurs de déterminer à quelles ressources balisées ils ont accès, autorisez l'accès utilisateur aux opérations d'API List telles que `ListCrawlers`, `ListDevEndpoints`, `ListJobs` et `ListTriggers`.
4. Refuser l'accès des utilisateurs à AWS Glue balisage APIs, tel que `TagResource` et `UntagResource`
5. Autorisez l'utilisateur à accéder aux détails de ressources à l'aide des opérations d'API BatchGet telles que `BatchGetCrawlers`, `BatchGetDevEndpoints`, `BatchGetJobs` et `BatchGetTriggers`.

Par exemple, lorsque vous appelez l'opération `ListCrawlers`, fournissez une valeur de balise pour correspondre au nom d'utilisateur. Ensuite, le résultat est une liste d'`crawlers` qui correspondent

aux valeurs de balise fournies. Fournissez la liste de noms à `BatchGetCrawlers` pour obtenir des détails sur chaque crawler avec la balise donnée.

Par exemple, si Tom ne doit être en mesure de récupérer que les détails des déclencheurs balisés avec Tom, l'administrateur peut ajouter des balises aux déclencheurs pour Tom, refuser à tous les utilisateurs l'accès à l'opération d'API `GetTriggers` et autoriser tous les utilisateurs à accéder à `ListTriggers` et à `BatchGetTriggers`.

Voici la politique en matière de ressources selon laquelle AWS Glue subventions d'administrateur à Tom. Dans la première section de la politique, AWS Glue Les opérations d'API sont refusées pour `GetTriggers`. Dans la deuxième section de la politique, les opérations `ListTriggers` sont autorisées pour toutes les ressources. Toutefois, dans la troisième section, les ressources balisées avec Tom sont autorisées à accéder avec l'accès `BatchGetTriggers`.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Deny",
      "Action": "glue:GetTriggers",
      "Resource": "*"
    },
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListTriggers"
      ],
      "Resource": [
        "*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "glue:BatchGetTriggers"
      ],
      "Resource": [
        "*"
      ],
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/Name": "Tom"
        }
      }
    }
  ]
}
```

```

    }
  }
}
}

```

En utilisant les mêmes déclencheurs que dans l'exemple précédent, Tom peut accéder au déclencheur t2, mais pas au déclencheur t1. L'exemple suivant montre les résultats lorsque Tom essaie d'accéder à t1 et t2 avec BatchGetTriggers.

```

aws glue batch-get-triggers --trigger-names t2
{
  "Triggers": {
    "State": "CREATED",
    "Type": "SCHEDULED",
    "Name": "t2",
    "Actions": [
      {
        "JobName": "j2"
      }
    ],
    "Schedule": "cron(0 0/1 * * ? *)"
  }
}

```

```
aws glue batch-get-triggers --trigger-names t1
```

An error occurred (AccessDeniedException) when calling the BatchGetTriggers operation:
No access to any requested resource.

L'exemple suivant montre les résultats lorsque Tom essaie d'accéder au déclencheur t2 et au déclencheur t3 (qui n'existe pas) dans le même appel BatchGetTriggers. Notez que, comme Tom a accès au déclencheur t2 et qu'il existe, seul t2 est renvoyé. Tom est autorisé à accéder au déclencheur t3, mais le déclencheur t3 n'existe pas, si bien que t3 est renvoyé comme réponse dans une liste de "TriggersNotFound": [].

```

aws glue batch-get-triggers --trigger-names t2 t3
{
  "Triggers": {
    "State": "CREATED",
    "Type": "SCHEDULED",
    "Name": "t2",

```

```
    "Actions": [
      {
        "JobName": "j2"
      }
    ],
    "TriggersNotFound": ["t3"],
    "Schedule": "cron(0 0/1 * * ? *)"
  }
}
```

Contrôler les paramètres à l'aide de clés de condition ou de contexte

Vous pouvez utiliser des clés de condition ou des clés contextuelles lorsque vous accordez des autorisations de création et de mise à jour de tâches. Ces sections traitent des clés :

- [Contrôler des politiques qui contrôlent les paramètres à l'aide des clés de condition](#)
- [Contrôler des politiques qui contrôlent les paramètres à l'aide des clés de contexte](#)

Contrôler des politiques qui contrôlent les paramètres à l'aide des clés de condition

AWS Glue fournit trois clés de condition IAM `glue:VpcIdsglue:SubnetIds`, `etglue:SecurityGroupIds`. Vous pouvez utiliser les clés de condition dans les politiques IAM lorsque vous accordez des autorisations de création et de mise à jour de tâches. Vous pouvez utiliser ce paramètre pour vous assurer que les tâches ou les sessions ne sont pas créées (ou mises à jour vers) pour s'exécuter en dehors de l'environnement VPC souhaité. Les informations de configuration du VPC ne proviennent pas directement de la `CreateJob` demande, mais sont déduites du champ « connexions » du travail qui pointe vers un AWS Glue connexion.

Exemple d'utilisation

Créez un AWS Glue connexion de type réseau nommée « traffic-monitored-connection » avec le `VpcId` « vpc-id1234 » souhaité, et. `SubnetIds` `SecurityGroupIds`

Spécifiez la condition des clés de condition pour le `CreateJob` et `UpdateJob` dans la politique IAM.

```
{
  "Effect": "Allow",
  "Action": [
    "glue:CreateJob",
    "glue:UpdateJob"
  ],
```

```
"Resource": [
  "*"
],
"Condition": {
  "ForAnyValue:StringLike": {
    "glue:VpcIds": [
      "vpc-id1234"
    ]
  }
}
```

Vous pouvez créer une politique IAM similaire pour interdire la création d'un AWS Glue tâche sans spécifier d'informations de connexion.

Restreindre les sessions sur VPCs

Pour obliger les sessions créées à s'exécuter au sein d'un VPC spécifique, vous limitez l'autorisation des rôles en ajoutant un effet Deny sur l'action `glue:CreateSession` à la condition que le `glue:vpc-id` ne soit pas égal à `vpc-<123>`. Par exemple :

```
"Effect": "Deny",
"Action": [
  "glue:CreateSession"
],
"Condition": {
  "StringNotEquals" : {"glue:VpcIds" : ["vpc-123"]}
}
```

Vous pouvez également obliger les sessions créées à s'exécuter au sein d'un VPC en ajoutant un effet Deny sur l'action `glue:CreateSession` à la condition que le `glue:vpc-id` soit nul. Par exemple :

```
{
  "Effect": "Deny",
  "Action": [
    "glue:CreateSession"
  ],
  "Condition": {
    "Null": {"glue:VpcIds": true}
  }
}
```

```
},  
{  
  "Effect": "Allow",  
  "Action": [  
    "glue:CreateSession"  
  ],  
  "Resource": ["*"]  
}
```

Contrôler des politiques qui contrôlent les paramètres à l'aide des clés de contexte

AWS Glue fournit une clé de contexte (`glue:CredentialIssuingService=glue.amazonaws.com`) à chaque session de rôle que AWS Glue met à la disposition du poste de travail et du point de terminaison du développeur. Cela vous permet de mettre en œuvre des contrôles de sécurité pour les actions entreprises par AWS Glue scripts. AWS Glue fournit une autre clé de contexte (`glue:RoleAssumedBy=glue.amazonaws.com`) à chaque session de rôle où AWS Glue appelle un autre AWS service au nom du client (pas par un point de terminaison `job/dev`, mais directement par le AWS Glue service).

Exemple d'utilisation

Spécifiez l'autorisation conditionnelle dans une politique IAM et attachez-la au rôle à utiliser par un AWS Glue travail. Cela garantit que certaines actions sont autorisées/refusées selon que la session de rôle est utilisée ou non pour un AWS Glue environnement d'exécution des tâches.

```
{  
  "Effect": "Allow",  
  "Action": "s3:GetObject",  
  "Resource": "arn:aws:s3:::amzn-s3-demo-bucket/*",  
  "Condition": {  
    "StringEquals": {  
      "glue:CredentialIssuingService": "glue.amazonaws.com"  
    }  
  }  
}
```

Refus de la possibilité de créer des sessions d'aperçu des données à une identité

Cette section contient un exemple de politique IAM utilisé pour refuser à une identité la possibilité de créer des sessions d'aperçu des données. Associez cette politique à l'identité, qui est distincte du rôle utilisé par la session d'aperçu des données lors de son exécution.

```
{
  "Sid": "DatapreviewDeny",
  "Effect": "Deny",
  "Action": [
    "glue:CreateSession"
  ],
  "Resource": [
    "arn:aws:glue:*:*:session/glue-studio-datapreview*"
  ]
}
```

Exemples de politiques basées sur les ressources pour Glue AWS

Cette section contient des exemples de politiques basées sur les ressources, y compris les politiques qui accordent l'accès intercompte.

Les exemples utilisent le AWS Command Line Interface (AWS CLI) pour interagir avec AWS Glue opérations d'API de service. Vous pouvez effectuer les mêmes opérations sur le AWS Glue console ou en utilisant l'une des AWS SDKs.

Important

En modifiant un AWS Glue politique en matière de ressources, vous risquez de révoquer accidentellement les autorisations existantes AWS Glue utilisateurs de votre compte et provoquer des perturbations inattendues. Essayez ces exemples uniquement dans les comptes de développement ou de test et assurez-vous qu'ils n'interrompent aucun workflow existant avant d'apporter des modifications.

Rubriques

- [Considérations relatives à l'utilisation de politiques basées sur les ressources avec Glue AWS](#)
- [Utiliser une politique de ressource pour contrôler l'accès dans le même compte](#)

Considérations relatives à l'utilisation de politiques basées sur les ressources avec Glue AWS

Note

Les politiques IAM et un AWS Glue la politique en matière de ressources met quelques secondes à se propager. Une fois que vous avez attaché une nouvelle politique, vous pouvez

remarquer que l'ancienne politique est toujours en vigueur jusqu'à ce que la nouvelle politique ait été appliquée à tout le système.

Vous utilisez un document de politique écrit au format JSON pour créer ou modifier une politique de ressource. La syntaxe de la politique est la même que pour une politique IAM basée sur l'identité (veuillez consulter la [Référence de politique JSON IAM](#)), avec les exceptions suivantes :

- Un bloc "Principal" ou "NotPrincipal" est requis pour chaque déclaration de politique.
- Le "Principal" ou "NotPrincipal" doit identifier les principaux existants valides. Les modèles de caractères génériques (tels que `arn:aws:iam::account-id:user/*`) ne sont pas autorisés.
- Le "Resource" bloc de la politique nécessite que toutes les ressources correspondent ARNs à la syntaxe d'expression régulière suivante (où la première %s est le *region*, et la seconde %s est le *account-id*) :

```
*arn:aws:glue:%s:%s:(\*|[a-zA-Z\*]+\/*?.*)
```

Par exemple, `arn:aws:glue:us-west-2:account-id:*` et `arn:aws:glue:us-west-2:account-id:database/default` sont autorisés, mais `*` est pas autorisé.

- Contrairement aux politiques basées sur l'identité, un AWS Glue la politique de ressources ne doit contenir que les Amazon Resource Names (ARNs) des ressources appartenant au catalogue auquel la politique est attachée. Cela commence ARNs toujours par `arn:aws:glue:`.
- Une politique ne peut pas faire en sorte que l'identité qui la crée ne puisse pas créer ou modifier de politiques.
- La taille d'un document JSON de politique de ressource ne peut pas dépasser 10 Ko.

Utiliser une politique de ressource pour contrôler l'accès dans le même compte

Dans cet exemple, un utilisateur administrateur du Compte A crée une politique de ressource qui accorde à l'utilisateur IAM Alice du Compte A un accès complet au catalogue. Alice n'a aucune politique IAM attachée.

Pour ce faire, l'utilisateur admin exécute la AWS CLI commande suivante.

```
# Run as admin of Account A
```



```
$ aws glue put-resource-policy --profile administrator-name --region us-west-2 --  
policy-in-json '{  
  "Version": "2012-10-17",  
  "Statement": [  
    {  
      "Principal": {  
        "AWS": [  
          "arn:aws:iam::account-A-id:user/Alice"  
        ]  
      },  
      "Effect": "Allow",  
      "Action": [  
        "glue:*"  
      ],  
      "Resource": [  
        "arn:aws:glue:us-west-2:account-A-id:"  
      ]  
    }  
  ]  
}'
```

Au lieu de saisir le document de politique JSON dans le cadre de votre AWS CLI commande, vous pouvez enregistrer un document de politique dans un fichier et référencer le chemin du fichier dans la AWS CLI commande, préfixé par `file://`. Voici un exemple de la façon dont vous pourriez procéder :

```
$ echo '{  
  "Version": "2012-10-17",  
  "Statement": [  
    {  
      "Principal": {  
        "AWS": [  
          "arn:aws:iam::account-A-id:user/Alice"  
        ]  
      },  
      "Effect": "Allow",  
      "Action": [  
        "glue:*"  
      ],  
      "Resource": [  
        "arn:aws:glue:us-west-2:account-A-id:"  
      ]  
    }  
  ]  
}'
```

```
]
}' > /temp/policy.json

$ aws glue put-resource-policy --profile admin1 \
  --region us-west-2 --policy-in-json file:///temp/policy.json
```

Une fois cette politique de ressources propagée, Alice peut accéder à toutes AWS Glue les ressources du compte A, comme suit.

```
# Run as user Alice
$ aws glue create-database --profile alice --region us-west-2 --database-input '{
  "Name": "new_database",
  "Description": "A new database created by Alice",
  "LocationUri": "s3://amzn-s3-demo-bucket"
}'

$ aws glue get-table --profile alice --region us-west-2 --database-name "default" --
table-name "tbl1"}
```

En réponse à l'`get-table` appel d'Alice, le AWS Glue le service renvoie ce qui suit.

```
{
  "Table": {
    "Name": "tbl1",
    "PartitionKeys": [],
    "StorageDescriptor": {
      .....
    },
    .....
  }
}
```

Octroi de politiques AWS gérées pour AWS Glue

Une politique AWS gérée est une politique autonome créée et administrée par AWS. AWS les politiques gérées sont conçues pour fournir des autorisations pour de nombreux cas d'utilisation courants afin que vous puissiez commencer à attribuer des autorisations aux utilisateurs, aux groupes et aux rôles.

N'oubliez pas que les politiques AWS gérées peuvent ne pas accorder d'autorisations de moindre privilège pour vos cas d'utilisation spécifiques, car elles sont accessibles à tous les AWS clients.

Nous vous recommandons de réduire encore les autorisations en définissant des [politiques gérées par le client](#) qui sont propres à vos cas d'utilisation.

Vous ne pouvez pas modifier les autorisations définies dans les politiques AWS gérées. Si les autorisations définies dans une politique AWS gérée sont AWS mises à jour, la mise à jour affecte toutes les identités principales (utilisateurs, groupes et rôles) auxquelles la politique est attachée. AWS est le plus susceptible de mettre à jour une politique AWS gérée lorsqu'une nouvelle politique Service AWS est lancée ou lorsque de nouvelles opérations d'API sont disponibles pour les services existants.

Pour plus d'informations, consultez [Politiques gérées par AWS](#) dans le Guide de l'utilisateur IAM.

AWS politiques gérées (prédéfinies) pour AWS Glue

AWS répond à de nombreux cas d'utilisation courants en fournissant des politiques IAM autonomes créées et administrées par AWS. Ces politiques AWS gérées accordent les autorisations nécessaires pour les cas d'utilisation courants afin que vous puissiez éviter d'avoir à rechercher les autorisations nécessaires. Pour plus d'informations, consultez [Politiques gérées par AWS](#) dans le Guide de l'utilisateur IAM.

Les politiques AWS gérées suivantes, que vous pouvez associer aux identités de votre compte, sont spécifiques à chaque scénario d'utilisation AWS Glue et sont regroupées par scénario d'utilisation :

- [AWSGlueConsoleFullAccess](#)— Accorde un accès complet aux AWS Glue ressources lorsqu'une identité à laquelle la politique est attachée utilise le AWS Management Console. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique est généralement attachée aux utilisateurs de la console AWS Glue.
- [AWSGlueServiceRole](#)— Accorde l'accès aux ressources dont AWS Glue les différents processus ont besoin pour s'exécuter en votre nom. Ces ressources incluent AWS Glue Amazon S3, IAM, CloudWatch Logs et Amazon EC2. Si vous suivez la convention de dénomination des ressources spécifiées dans la politique, les processus AWS Glue ont les autorisations requises. Cette politique est généralement attachée aux rôles spécifiés lorsque vous définissez les crawlers, les tâches et les points de terminaison de développement.
- [AwsGlueSessionUserRestrictedServiceRole](#)— Fournit un accès complet à toutes les AWS Glue ressources, à l'exception des sessions. Elle permet aux utilisateurs de créer et d'utiliser uniquement les séances interactives associées à l'utilisateur. Cette politique inclut les autres autorisations nécessaires AWS Glue pour gérer les AWS Glue ressources d'autres AWS services.

La politique permet également d'ajouter des balises aux AWS Glue ressources d'autres AWS services.

 Note

Pour bénéficier de tous les avantages de la sécurité, n'accordez pas cette politique à un utilisateur qui a reçu la politique `AWSGlueServiceRole`, `AWSGlueConsoleFullAccess`, ou `AWSGlueConsoleSageMakerNotebookFullAccess`.

- [`AwsGlueSessionUserRestrictedPolicy`](#)— Permet de créer des sessions AWS Glue interactives à l'aide de l'opération `CreateSession` API uniquement si une clé de balise « propriétaire » et une valeur correspondant à l'ID AWS utilisateur du destinataire sont fournies. Cette politique d'identité est associée à l'utilisateur IAM qui appelle l'opération d'API `CreateSession`. Cette politique permet également à la personne assignée d'interagir avec les ressources de session AWS Glue interactives créées avec une balise « propriétaire » et une valeur correspondant à son ID AWS utilisateur. Cette politique refuse l'autorisation de modifier ou de supprimer les balises « propriétaire » d'une ressource AWS Glue de séance après la création de la séance.

 Note

Pour bénéficier de tous les avantages de la sécurité, n'accordez pas cette politique à un utilisateur qui a reçu la politique `AWSGlueServiceRole`, `AWSGlueConsoleFullAccess`, ou `AWSGlueConsoleSageMakerNotebookFullAccess`.

- [`AwsGlueSessionUserRestrictedNotebookServiceRole`](#)— Fournit un accès suffisant à la session du AWS Glue Studio bloc-notes pour interagir avec des ressources de session AWS Glue interactives spécifiques. Il s'agit de ressources créées avec la valeur de balise « owner » qui correspond à l'ID AWS utilisateur du principal (utilisateur ou rôle IAM) qui crée le bloc-notes. Pour en savoir plus sur ces balises, veuillez consulter le diagramme [Valeurs de la clé du principal](#) dans le Guide de l'utilisateur IAM.

Cette politique de fonction du service est attachée au rôle spécifié par une commande magique dans le bloc-notes ou transmise en tant que rôle à l'opération d'API `CreateSession`. Cette politique permet également au principal de créer une session AWS Glue interactive à partir de l'interface du AWS Glue Studio bloc-notes uniquement si la clé de balise « propriétaire » et la valeur correspondent à AWS l'ID utilisateur du principal. Cette politique refuse l'autorisation de modifier ou de supprimer les balises « propriétaire » d'une ressource AWS Glue de séance après la création de la séance. Cette politique inclut également les autorisations d'écriture et de lecture à

partir de compartiments Amazon S3, de rédaction de CloudWatch journaux, ainsi que de création et de suppression de balises pour les EC2 ressources Amazon utilisées par AWS Glue.

 Note

Pour obtenir tous les avantages en matière de sécurité, n'accordez pas cette politique à un rôle qui a été attribué à la politique `AWSGlueServiceRole`, `AWSGlueConsoleFullAccess`, ou `AWSGlueConsoleSageMakerNotebookFullAccess`.

- [AwsGlueSessionUserRestrictedNotebookPolicy](#)— Permet de créer une session AWS Glue interactive à partir de l'interface du AWS Glue Studio bloc-notes uniquement s'il existe une clé de balise « propriétaire » et une valeur correspondant à l'ID de l'AWS utilisateur principal (utilisateur ou rôle IAM) qui crée le bloc-notes. Pour en savoir plus sur ces balises, veuillez consulter le diagramme [Valeurs de la clé du principal](#) dans le Guide de l'utilisateur IAM.

Cette politique est attachée au principal (utilisateur ou rôle IAM) qui crée des séances à partir de l'interface de bloc-notes AWS Glue Studio. Cette politique permet également un accès suffisant au bloc-notes AWS Glue Studio pour interagir avec des ressources de séances interactives AWS Glue spécifiques. Il s'agit de ressources créées avec la valeur de balise « owner » qui correspond à l'ID utilisateur du principal. Cette politique refuse l'autorisation de modifier ou de supprimer les balises « propriétaire » d'une ressource AWS Glue de séance après la création de la séance.

- [AWSGlueServiceNotebookRole](#)— Accorde l'accès aux AWS Glue sessions démarrées dans un AWS Glue Studio bloc-notes. Cette politique permet de répertorier et d'obtenir des informations de session pour toutes les sessions, mais permet uniquement aux utilisateurs de créer et d'utiliser les sessions étiquetées avec leur ID AWS utilisateur. Cette politique refuse l'autorisation de modifier ou de supprimer les balises « propriétaire » des ressources de AWS Glue session étiquetées avec leur AWS ID.

Attribuez cette politique à l'AWS utilisateur qui crée des tâches à l'aide de l'interface du bloc-notes dans AWS Glue Studio.

- [AWSGlueConsoleSageMakerNotebookFullAccess](#)— Accorde un accès complet à AWS Glue et aux ressources d'Amazon SageMaker IA lorsque l'identité à laquelle la politique est attachée utilise la console AWS Management Console. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la console AWS Glue qui gèrent des blocs-notes dotés d'Amazon SageMaker intelligence artificielle.

- [AWSGlueSchemaRegistryFullAccess](#)— Accorde un accès complet aux ressources du registre des AWS Glue schémas lorsque l'identité à laquelle la politique est attachée utilise le AWS Management Console ou AWS CLI. Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique est généralement attachée aux utilisateurs de la AWS Glue console ou aux utilisateurs AWS CLI qui gèrent le registre des AWS Glue schémas.
- [AWSGlueSchemaRegistryReadOnlyAccess](#)— Accorde un accès en lecture seule aux ressources du registre des AWS Glue schémas lorsqu'une identité à laquelle la politique est attachée utilise le AWS Management Console ou. AWS CLI Si vous suivez la convention de dénomination pour les ressources spécifiées dans la politique, les utilisateurs bénéficient des capacités totales de la console. Cette politique s'applique généralement aux utilisateurs de la AWS Glue console ou à AWS CLI ceux qui utilisent le registre des AWS Glue schémas.

 Note

Vous pouvez consulter ces politiques d'autorisations en vous connectant à la console IAM et en y recherchant des politiques spécifiques.

Vous pouvez également créer vos propres stratégies IAM personnalisées afin d'accorder des autorisations pour les actions et les ressources AWS Glue. Vous pouvez attacher ces politiques personnalisées aux utilisateurs ou groupes IAM qui nécessitent ces autorisations.

Pour créer une connexion avec une configuration VPC tout en utilisant un rôle IAM personnalisé, celui-ci doit disposer des actions d'accès VPC suivantes :

- responsable des secrets : GetSecretValue
- responsable des secrets : PutSecretValue
- responsable des secrets : DescribeSecret
- EC2 : CreateNetworkInterface
- EC2 : DeleteNetworkInterface
- EC2 : DescribeNetworkInterfaces
- EC2 : DescribeSubnets

AWS Glue les mises à jour dans les politiques AWS gérées

Consultez les détails des mises à jour apportées aux politiques AWS gérées pour AWS Glue depuis que ce service a commencé à suivre ces modifications. Pour recevoir des alertes automatiques concernant les modifications apportées à cette page, abonnez-vous au flux RSS sur la page d'historique du document AWS Glue.

Modification	Description	Date
AwsGlueSessionUserRestrictcdNotebookPolicy — Mise à jour mineure d'une politique existante.	Ajoutez une autorisation d'glue:TagResource action sur la clé du tag du propriétaire. Nécessaire tag-on-create pour la prise en charge des sessions avec clé d'identification du propriétaire.	30 août 2024
AwsGlueSessionUserRestrictcdNotebookServiceRole — Mise à jour mineure d'une politique existante.	Ajoutez une autorisation d'glue:TagResource action sur la clé du tag du propriétaire. Nécessaire tag-on-create pour la prise en charge des sessions avec clé d'identification du propriétaire.	30 août 2024
AwsGlueSessionUserRestrictcdPolicy — Mise à jour mineure d'une politique existante.	Ajoutez une autorisation d'glue:TagResource action sur la clé du tag du propriétaire. Nécessaire tag-on-create pour la prise en charge des sessions avec clé d'identification du propriétaire.	5 août 2024
AwsGlueSessionUserRestrictcdServiceRole — Mise à jour mineure d'une politique existante.	Ajoutez une autorisation d'glue:TagResource action sur la clé du tag du propriétaire. Nécessaire tag-on-create pour la prise en charge des	5 août 2024

Modification	Description	Date
	sessions avec clé d'identification du propriétaire.	
AwsGlueSessionUserRestrictedPolicy — Mise à jour mineure d'une politique existante.	Ajout de <code>glue:StartCompletion</code> et de <code>glue:GetCompletion</code> à la politique. Nécessaire pour l'intégration des données Amazon Q dans AWS Glue.	30 avril 2024
AwsGlueSessionUserRestrictedNotebookServiceRole — Mise à jour mineure d'une politique existante.	Ajout de <code>glue:StartCompletion</code> et de <code>glue:GetCompletion</code> à la politique. Nécessaire pour l'intégration des données Amazon Q dans AWS Glue.	30 avril 2024
AwsGlueSessionUserRestrictedServiceRole — Mise à jour mineure d'une politique existante.	Ajout de <code>glue:StartCompletion</code> et de <code>glue:GetCompletion</code> à la politique. Nécessaire pour l'intégration des données Amazon Q dans AWS Glue.	30 avril 2024
AWSGlueServiceNotebookRole — Mise à jour mineure d'une politique existante.	Ajout de <code>glue:StartCompletion</code> et de <code>glue:GetCompletion</code> à la politique. Nécessaire pour l'intégration des données Amazon Q dans AWS Glue.	30 janvier 2024

Modification	Description	Date
AwsGlueSessionUserRestrictcdNotebookPolicy — Mise à jour mineure d'une politique existante.	Ajout de <code>glue:StartCompletion</code> et de <code>glue:GetCompletion</code> à la politique. Nécessaire pour l'intégration des données Amazon Q dans AWS Glue.	29 novembre 2023
AWSGlueServiceNotebookRole — Mise à jour mineure d'une politique existante.	Ajouter une stratégie <code>codewhisperer:GenerateRecommendations</code> . Nécessaire pour une nouvelle fonctionnalité dans laquelle AWS Glue génère CodeWhisperer des recommandations.	9 octobre 2023
AWSGlueServiceRole — Mise à jour mineure d'une politique existante.	Resserrez la portée des CloudWatch autorisations pour mieux refléter AWS la journalisation de Glue.	4 août 2023
AWSGlueConsoleFullAccess — Mise à jour mineure d'une politique existante.	Ajoutez les autorisations <code>Lister et Décrire de la recette databrew</code> à la stratégie. Nécessaire pour fournir un accès administratif complet aux nouvelles fonctionnalités permettant à AWS Glue d'accéder aux recettes.	9 mai 2023

Modification	Description	Date
AWSGlueConsoleFullAccess — Mise à jour mineure d'une politique existante.	Ajouter une stratégie <code>cloudformation:ListStacks</code> Préserve les fonctionnalités existantes après modification des exigences AWS CloudFormation d'autorisation.	28 mars 2023
Nouvelles politiques gérées ajoutées pour la fonctionnalité de séances interactives : - AwsGlueSessionUserRestrictedServiceRole - AwsGlueSessionUserRestrictedPolicy - AwsGlueSessionUserRestrictedNotebookServiceRole - AwsGlueSessionUserRestrictedNotebookPolicy	Ces politiques ont été conçues pour fournir une sécurité supplémentaire pour les séances interactives et les blocs-notes dans AWS Glue Studio. Les politiques limitent l'accès à l'opération d'API <code>CreateSession</code> pour que seul le propriétaire ait accès.	30 novembre 2021

Modification	Description	Date
AWSGlueConsoleSageMakerNotebookFullAccess — Mise à jour d'une politique existante.	Suppression d'un ARN (<code>arn:aws:s3:::aws-glue-*/*</code>) de ressource redondante pour l'action qui octroie des autorisations de lecture/écriture aux compartiments Amazon S3 que AWS Glue utilise pour stocker des scripts et des fichiers temporaires. Correction d'un problème de syntaxe en remplaçant <code>"StringEquals"</code> par <code>"ForAnyValue:StringLike"</code>, et changement de place des lignes <code>"Effect": "Allow"</code> pour qu'elles précèdent la ligne <code>"Action":</code> dans chaque endroit où elles n'étaient pas dans l'ordre.	15 juillet 2021
AWSGlueConsoleFullAccess — Mise à jour d'une politique existante.	Suppression d'un ARN (<code>arn:aws:s3:::aws-glue-*/*</code>) de ressource redondante pour l'action qui octroie des autorisations de lecture/écriture aux compartiments Amazon S3 que AWS Glue utilise pour stocker des scripts et des fichiers temporaires.	15 juillet 2021

Modification	Description	Date
AWS Glue a démarré le suivi des modifications.	AWS Glue a commencé à suivre les modifications apportées AWS à ses politiques gérées.	10 juin 2021

Spécification AWS Glue ressource ARNs

Entrée AWS Glue, vous pouvez contrôler l'accès aux ressources à l'aide d'une politique AWS Identity and Access Management (IAM). Dans une politique, vous utilisez un Amazon Resource Name (ARN) pour identifier la ressource à laquelle la politique s'applique. Toutes les ressources ne sont pas dans AWS Glue soutien ARNs.

Rubriques

- [Catalogue de données ARNs](#)
- [ARNs pour les objets ne figurant pas dans le catalogue dans AWS Glue](#)
- [Contrôle d'accès pour AWS Glue opérations d'API singulières hors catalogue](#)
- [Contrôle d'accès pour AWS Glue opérations d'API hors catalogue qui récupèrent plusieurs éléments](#)
- [Contrôle d'accès pour AWS Glue opérations d' BatchGet API hors catalogue](#)

Catalogue de données ARNs

Les ressources du catalogue de données ont une structure hiérarchique, avec `catalog` comme racine.

```
arn:aws:glue:region:account-id:catalog
```

Chaque AWS compte possède un seul catalogue de données dans une AWS région avec l'identifiant de compte à 12 chiffres comme identifiant de catalogue. Les ressources sont ARNs associées à des ressources uniques, comme indiqué dans le tableau suivant.

Type de ressource	Format ARN
Catalogue	arn:aws:glue: <i>region</i> : <i>account-id</i> :catalog

Type de ressource	Format ARN
	Par exemple : <code>arn:aws:glue:us-east-1:123456789012:catalog</code>
Base de données	<code>arn:aws:glue: <i>region</i>:<i>account-id</i> :database/ <i>database name</i></code> Par exemple : <code>arn:aws:glue:us-east-1:123456789012:database/db1</code>
Tableau	<code>arn:aws:glue: <i>region</i>:<i>account-id</i> :table/<i>database name</i>/<i>table name</i></code> Par exemple : <code>arn:aws:glue:us-east-1:123456789012:table/db1/tbl1</code>
Catalogue de tables S3 fédéré (tous les compartiments de tables)	<code>arn:aws:glue: <i>region</i>:<i>account-id</i> :catalog/s3tablescatalog</code> Par exemple : <code>arn:aws:glue:us-east-1:123456789012:catalog/s3tablescatalog</code>
Catalogue de compartiments de tables S3 fédéré (catalogue enfant)	<code>arn:aws:glue: <i>region</i>:<i>account-id</i> :catalog/s3tablescatalog/ <i>bucket name</i></code> Par exemple : <code>arn:aws:glue:us-east-1:123456789012:catalog/s3tablescatalog/amzn-s3-demo-bucket1</code>
Base de données de tables S3 fédérées	<code>arn:aws:glue: <i>region</i>:<i>account-id</i> :database/s3tablescatalog/ <i>child catalog name</i>/<i>database name</i></code> Par exemple : <code>arn:aws:glue:us-east-1:123456789012:database/s3tablescatalog/amzn-s3-demo-bucket1/nsdb1</code>

Type de ressource	Format ARN
Table S3 fédérée	arn:aws:glue: <i>region:account-id</i> :table/s3tablescatalog/ <i>child catalog name/database name/table name</i> Par exemple : arn:aws:glue:us-east-1:123456789012:table/s3tablescatalog/amzn-s3-demo-bucket1/nsdb1/s3tbl1
Catalogue de tables S3 fédéré (un bucket de tables unique enregistré auprès de Lake Formation)	arn:aws:glue: <i>region:account-id</i> :catalog/<i>catalog name</i> Par exemple : arn:aws:glue:us-east-1:123456789012:catalog/amzn-s3-demo-bucket1
Base de données de tables S3 fédérées	arn:aws:glue: <i>region:account-id</i> :catalog/<i>catalog name/database name</i> Par exemple : arn:aws:glue:us-east-1:123456789012:database/amzn-s3-demo-bucket1/nsdb1
Table S3 fédérée	arn:aws:glue: <i>region:account-id</i> :catalog/<i>catalog name/database name/table name</i> Par exemple : arn:aws:glue:us-east-1:123456789012:table/amzn-s3-demo-bucket1/ <i>nsdb1/s3tbl1</i>
Catalogue fédéré ou géré (catalogue de premier niveau dans un catalogue multiple)	arn:aws:glue: <i>region:account-id</i> :catalog/ <i>top-level catalog name</i> Par exemple : arn:aws:glue:us-east-1:123456789012:catalog/nscatalog Le format ARN d'un catalogue géré suit la même structure.

Type de ressource	Format ARN
Catalogue fédéré à plusieurs niveaux (catalogue enfant dans un catalogue à plusieurs niveaux)	arn:aws:glue: <i>region:account-id</i> :catalog/ <i>top-level catalog name/child catalog name</i> Par exemple : arn:aws:glue:us-east-1:123456789012:catalog/nscatalog/dbcatalog
Base de données fédérée	arn:aws:glue: <i>region:account-id</i> :database/ <i>name space catalog name/child catalog name/database name</i> Par exemple : arn:aws:glue:us-east-1:123456789012:database/nscatalog/dbcatalog/schemadb
Table fédérée	arn:aws:glue: <i>region:account-id</i> :table/<i>name space catalog name/child catalog name/database name/table name</i> Par exemple : arn:aws:glue:us-east-1:123456789012:table/nscatalog/dbcatalog/schemadb/rstbl1
Conteneur de liens vers le catalogue	arn:aws:glue: <i>region:account-id</i> :catalog/<i>link container name</i> Par exemple : arn:aws:glue:glue:us-east-1:123456789012:catalog /linkcontainer-example
Base de données	arn:aws:glue: <i>region:account-id</i> :catalog/<i>link container name/database name</i> Par exemple : arn:aws:glue:glue:us-east-1:123456789012:database /linkcontainer-example/link-db
Fonction définie par l'utilisateur	arn:aws:glue: <i>region:account-id</i> :userDefinedFunction/ <i>database name/user-defined function name</i> Par exemple : arn:aws:glue:us-east-1:123456789012:userDefinedFunction/db1/func1

Type de ressource	Format ARN
Connexion	<code>arn:aws:glue: <i>region</i>:<i>account-id</i> :connection/ <i>connection name</i></code> Par exemple : <code>arn:aws:glue:us-east-1:123456789012:connection/connection1</code>
Séance interactive	<code>arn:aws:glue: <i>region</i>:<i>account-id</i> :session/ <i>interactive session id</i></code> Par exemple : <code>arn:aws:glue:us-east-1:123456789012:session/a1b2c3d4-5678-90ab-cdef-EXAMPLE11111</code>

Pour permettre un contrôle d'accès précis, vous pouvez les utiliser ARNs dans vos politiques IAM et vos politiques de ressources pour accorder ou refuser l'accès à des ressources spécifiques. Les caractères génériques sont autorisés dans les politiques. Par exemple, l'ARN suivant correspond à toutes les tables de la base de données default.

```
arn:aws:glue:us-east-1:123456789012:table/default/*
```

Important

Toutes les opérations effectuées sur une ressource du catalogue de données requièrent une autorisation sur la ressource et tous les ancêtres de cette ressource. Par exemple, la création d'une partition pour une table nécessite l'autorisation sur la table, la base de données et le catalogue où se trouve la table. L'exemple suivant montre l'autorisation requise pour créer des partitions sur la table `PrivateTable` dans la base de données `PrivateDatabase` du catalogue de données.

```
{
  "Sid": "GrantCreatePartitions",
  "Effect": "Allow",
  "Action": [
    "glue:BatchCreatePartitions"
  ],
  "Resource": [
    "arn:aws:glue:us-east-1:123456789012:table/PrivateDatabase/PrivateTable",
```



```

    "arn:aws:glue:us-east-1:123456789012:database/PrivateDatabase",
    "arn:aws:glue:us-east-1:123456789012:catalog"
  ]
}
```

Outre l'autorisation sur la ressource et tous ses ancêtres, toutes les opérations de suppression nécessitent une autorisation sur tous les enfants de cette ressource. Par exemple, pour supprimer une base de données, il faut l'autorisation sur toutes les tables et les fonctions définies par l'utilisateur dans la base de données, ainsi que sur la base de données et le catalogue dans lequel se trouve la base de données. L'exemple suivant montre l'autorisation requise pour supprimer une base de données `PrivateDatabase` dans le catalogue de données.

```

{
  "Sid": "GrantDeleteDatabase",
  "Effect": "Allow",
  "Action": [
    "glue:DeleteDatabase"
  ],
  "Resource": [
    "arn:aws:glue:us-east-1:123456789012:table/PrivateDatabase/*",
    "arn:aws:glue:us-east-1:123456789012:userDefinedFunction/PrivateDatabase/*",
    "arn:aws:glue:us-east-1:123456789012:database/PrivateDatabase",
    "arn:aws:glue:us-east-1:123456789012:catalog"
  ]
}
```

En résumé, les actions sur les ressources du catalogue de données suivent ces règles d'autorisation :

- Les actions sur le catalogue requièrent l'autorisation sur le catalogue uniquement.
- Les actions sur une base de données requièrent l'autorisation sur la base de données et le catalogue.
- Les actions de suppression sur une base de données requièrent l'autorisation sur la base de données et le catalogue, ainsi que sur toutes les tables et les fonctions définies par l'utilisateur dans la base de données.
- Les actions sur une table, une partition ou une version de table requièrent l'autorisation sur la table, la base de données et le catalogue.

- Les actions sur une fonction définie par l'utilisateur requièrent l'autorisation sur la fonction définie par l'utilisateur, la base de données et le catalogue.
- Les actions sur une connexion requièrent l'autorisation sur la connexion et le catalogue.

ARNs pour les objets ne figurant pas dans le catalogue dans AWS Glue

Momentanée AWS Glue les ressources autorisent des autorisations au niveau des ressources pour contrôler l'accès à l'aide d'un ARN. Vous pouvez les utiliser ARNs dans vos politiques IAM pour permettre un contrôle d'accès précis. Le tableau suivant répertorie les ressources qui peuvent contenir des ressources ARNs.

Type de ressource	Format ARN
crawler	<code>arn:aws:glue: <i>region</i>:<i>account-id</i> :crawler/ <i>crawler-name</i></code> Par exemple : <code>arn:aws:glue:us-east-1:123456789012:crawler/mycrawler</code>
Tâche	<code>arn:aws:glue: <i>region</i>:<i>account-id</i> :job/<i>job-name</i></code> Par exemple : <code>arn:aws:glue:us-east-1:123456789012:job/testjob</code>
Déclencheur	<code>arn:aws:glue: <i>region</i>:<i>account-id</i> :trigger/ <i>trigger-name</i></code> Par exemple : <code>arn:aws:glue:us-east-1:123456789012:trigger/sampletrigger</code>
Point de terminaison de développement	<code>arn:aws:glue: <i>region</i>:<i>account-id</i> :devEndpoint/ <i>development-endpoint-name</i></code> Par exemple : <code>arn:aws:glue:us-east-1:123456789012:devEndpoint/temporarydevendpoint</code>
Transformation de machine learning	<code>arn:aws:glue: <i>region</i>:<i>account-id</i> :mlTransform/ <i>transform-id</i></code>

Type de ressource	Format ARN
	Par exemple : <code>arn:aws:glue:us-east-1:123456789012:mlTransform/tfm-1234567890</code>

Contrôle d'accès pour AWS Glue opérations d'API singulières hors catalogue

AWS Glue les opérations d'API singulières hors catalogue agissent sur un seul élément (point de terminaison de développement). Des exemples sont `GetDevEndpoint`, `CreateUpdateDevEndpoint` et `UpdateDevEndpoint`. Pour ces opérations, une politique doit placer le nom de l'API dans le bloc "action" et l'ARN de la ressource dans le bloc "resource".

Supposons que vous souhaitiez autoriser un utilisateur à appeler l'opération `GetDevEndpoint`. La politique suivante accorde les autorisations nécessaires minimales à un point de terminaison nommé `myDevEndpoint-1`.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "MinimumPermissions",
      "Effect": "Allow",
      "Action": "glue:GetDevEndpoint",
      "Resource": "arn:aws:glue:us-east-1:123456789012:devEndpoint/
myDevEndpoint-1"
    }
  ]
}
```

La politique suivante autorise l'accès `UpdateDevEndpoint` aux ressources qui correspondent à `myDevEndpoint-` avec un caractère générique (*).

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "PermissionWithWildcard",
      "Effect": "Allow",
      "Action": "glue:UpdateDevEndpoint",
```

```

    "Resource": "arn:aws:glue:us-east-1:123456789012:devEndpoint/myDevEndpoint-
* "
    }
  ]
}

```

Vous pouvez combiner les deux politiques, comme dans l'exemple suivant. Il se peut que vous constatiez `EntityNotFoundException` pour n'importe quel point de terminaison de développement dont le nom commence par A. Toutefois, une erreur d'accès refusé est renvoyé lorsque vous essayez d'accéder à d'autres points de terminaison de développement.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "CombinedPermissions",
      "Effect": "Allow",
      "Action": [
        "glue:UpdateDevEndpoint",
        "glue:GetDevEndpoint"
      ],
      "Resource": "arn:aws:glue:us-east-1:123456789012:devEndpoint/A*"
    }
  ]
}

```

Contrôle d'accès pour AWS Glue opérations d'API hors catalogue qui récupèrent plusieurs éléments

Momentanée AWS Glue Les opérations d'API récupèrent plusieurs éléments (tels que plusieurs points de terminaison de développement) ; par exemple, `GetDevEndpoints`. Pour cette opération, vous ne pouvez spécifier qu'une ressource générique (*), et non une ressource spécifique ARNs.

Par exemple, pour inclure `GetDevEndpoints` dans la politique, la ressource doit être définie avec le caractère générique (*). Les opérations uniques (`GetDevEndpoint`, `CreateDevEndpoint` et `DeleteDevEndpoint`) sont également définies pour toutes les ressources (*) de l'exemple.

```

{
    "Sid": "PluralAPIIncluded",
    "Effect": "Allow",

```

```
    "Action": [
      "glue:GetDevEndpoints",
      "glue:GetDevEndpoint",
      "glue:CreateDevEndpoint",
      "glue:UpdateDevEndpoint"
    ],
    "Resource": [
      "*"
    ]
  }
```

Contrôle d'accès pour AWS Glue opérations d' BatchGet API hors catalogue

Momentanée AWS Glue Les opérations d'API récupèrent plusieurs éléments (tels que plusieurs points de terminaison de développement) ; par exemple, `BatchGetDevEndpoints`. Pour cette opération, vous pouvez spécifier un ARN pour limiter la portée des ressources qui sont accessibles.

Par exemple, pour autoriser l'accès à un point de terminaison de développement spécifique, incluez `BatchGetDevEndpoints` dans la politique avec son ARN de ressource.

```
{
  "Sid": "BatchGetAPIIncluded",
  "Effect": "Allow",
  "Action": [
    "glue:BatchGetDevEndpoints"
  ],
  "Resource": [
    "arn:aws:glue:us-east-1:123456789012:devEndpoint/de1"
  ]
}
```

Avec cette politique, vous pouvez accéder correctement au point de terminaison de développement nommé `de1`. Toutefois, si vous tentez d'accéder au point de terminaison de développement nommé `de2`, une erreur est renvoyée.

```
An error occurred (AccessDeniedException) when calling the BatchGetDevEndpoints
operation: No access to any requested resource.
```

⚠ Important

Pour d'autres approches de la configuration des politiques IAM, telles que l'utilisation des opérations d'API List et BatchGet, consultez [Exemples de politiques basées sur l'identité pour Glue AWS](#).

Octroi d'un accès intercompte

L'octroi d'un accès intercompte aux ressources du catalogue de données permet à vos tâches Extract-transform-load (ETL) d'interroger et de joindre des données provenant de comptes différents.

Rubriques

- [Méthodes d'octroi d'un accès entre comptes dans AWS Glue](#)
- [Ajouter ou mettre à jour la politique de ressource du catalogue de données](#)
- [Créer un appel d'API intercompte](#)
- [Créez un appel ETL intercompte](#)
- [Journalisation entre comptes CloudTrail](#)
- [Propriété et facturation des ressources intercomptes](#)
- [Limitations des accès inter-comptes](#)

Méthodes d'octroi d'un accès entre comptes dans AWS Glue

Vous pouvez autoriser l'accès à vos données à des AWS comptes externes en utilisant AWS Glue méthodes ou en utilisant des subventions AWS Lake Formation intercomptes. Le AWS Glue les méthodes utilisent des politiques AWS Identity and Access Management (IAM) pour obtenir un contrôle d'accès précis. Lake Formation utilise un modèle d'autorisations GRANT/REVOKE plus simple similaire aux commandes GRANT/REVOKE dans un système de base de données relationnelle.

Cette section décrit l'utilisation du AWS Glue méthodes. Pour de plus amples informations sur l'utilisation des autorisations intercomptes Lake Formation, consultez [Octroi des autorisations Lake Formation](#) dans le Guide du développeur AWS Lake Formation .

Il y en a deux AWS Glue méthodes pour accorder un accès multicompte à une ressource :

- Utilisation d'une politique de ressources de catalogue de données
- Utilisation d'un rôle IAM

Octroi d'un accès intercompte à l'aide d'une politique de ressource

Voici les étapes générales d'octroi d'un accès intercompte à l'aide d'une politique de ressource de catalogue de données :

1. Un administrateur (ou toute autre identité autorisée) d'un compte A attache une politique de ressource au catalogue de données dans le compte A. Cette politique accorde au compte B des autorisations intercomptes spécifiques pour effectuer des opérations sur une ressource dans le catalogue du compte A.
2. Un administrateur du compte B attache une politique IAM à une identité IAM dans le compte B qui délègue les autorisations reçues du compte A.

L'identité du compte B a désormais accès à la ressource spécifiée dans le compte A.

L'identité a besoin d'une autorisation accordée à la fois par le propriétaire de la ressource (compte A) et son compte parent (compte B) afin d'être en mesure d'accéder à la ressource.

Octroi d'un accès intercompte avec un rôle IAM

Voici les étapes générales d'octroi d'un accès intercompte à l'aide d'un rôle IAM :

1. Un administrateur (ou toute autre identité autorisée) dans le compte qui possède la ressource (compte A) crée un rôle IAM.
2. L'administrateur du Compte A attache une politique au rôle qui accorde des autorisations intercomptes pour l'accès à la ressource en question.
3. L'administrateur du compte A attache une politique d'approbation au rôle qui identifie une identité IAM dans un compte différent (compte B) comme principal pouvant assumer le rôle.

Le principal de la politique de confiance peut également être un directeur de AWS service si vous souhaitez accorder à un AWS service l'autorisation d'assumer ce rôle.

4. Un administrateur dans le compte B délègue désormais des autorisations à une ou plusieurs identités IAM du compte B afin qu'elle puisse assumer ce rôle. Cela donne à ces identités du compte B l'accès à la ressource du compte A.

Pour plus d'informations sur l'utilisation d'IAM pour déléguer des autorisations, veuillez consulter la section [Access management](#) (français non garanti) dans le Guide de l'utilisateur IAM. Pour plus d'informations sur les utilisateurs, les groupes, les rôles et les autorisations, consultez [Identités \(utilisateurs, groupes et rôles\)](#) dans le Guide de l'utilisateur IAM.

Pour une comparaison de ces deux approches, consultez la section En [quoi les rôles IAM diffèrent des politiques basées sur les ressources](#) dans le Guide de l'utilisateur IAM. AWS Glue prend en charge les deux options, avec la restriction selon laquelle une politique de ressources ne peut accorder l'accès qu'aux ressources du catalogue de données.

Par exemple, pour accorder au rôle Dev du compte B l'accès à la base de données db1 du compte A, attachez la politique de ressources suivante au catalogue du compte A.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:GetDatabase"
      ],
      "Principal": {"AWS": [
        "arn:aws:iam::account-B-id:role/Dev"
      ]},
      "Resource": [
        "arn:aws:glue:us-east-1:account-A-id:catalog",
        "arn:aws:glue:us-east-1:account-A-id:database/db1"
      ]
    }
  ]
}
```

En outre, le compte B devrait attacher la politique IAM suivante au rôle Dev avant d'obtenir l'accès à db1 sur le compte A.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:GetDatabase"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:account-A-id:catalog",
        "arn:aws:glue:us-east-1:account-A-id:database/db1"
      ]
    }
  ]
}
```



```
}  
]  
}
```

Ajouter ou mettre à jour la politique de ressource du catalogue de données

Vous pouvez ajouter ou mettre à jour le AWS Glue Politique de ressources du catalogue de données à l'aide de la console, de l'API ou AWS Command Line Interface (AWS CLI).

Important

Si vous avez déjà accordé des autorisations intercomptes à partir de votre compte avec AWS Lake Formation, l'ajout ou la mise à jour de la politique de ressource du catalogue de données nécessite une étape supplémentaire. Pour plus d'informations, voir [Gestion des autorisations entre comptes à l'aide des deux AWS Glue et Lake Formation](#) in the AWS Lake Formation Developer Guide.

Pour déterminer s'il existe des octrois intercomptes Lake Formation, utilisez l'opération d'API `glue:GetResourcePolicies` ou l' AWS CLI. Si `glue:GetResourcePolicies` renvoie des politiques autres qu'une politique de catalogue de données existante, les octrois Lake Formation existent. Pour plus d'informations, consultez la section [Affichage de toutes les subventions entre comptes à l'aide du fonctionnement de l' GetResourcePolicies API](#) dans le Guide du AWS Lake Formation développeur.

Pour ajouter ou mettre à jour la politique de ressource du catalogue de données (console)

1. Ouvrez le fichier AWS Glue console à <https://console.aws.amazon.com/glue/>.

Connectez-vous en tant qu'utilisateur administratif AWS Identity and Access Management (IAM) `glue:PutResourcePolicy` autorisé.

2. Dans le panneau de navigation, sélectionnez Settings (Paramètres).
3. Dans la page Paramètres du catalogue de données, sous Permissions (Autorisations), collez une politique de ressource dans la zone de texte. Ensuite, choisissez Save (Enregistrer).

Si la console affiche une alerte indiquant que les autorisations de la politique s'ajouteront aux autorisations accordées à l'aide de Lake Formation, sélectionnez Proceed (Continuer).

Pour ajouter ou mettre à jour la politique de ressource du catalogue de données (AWS CLI)

- Soumettez une commande `aws glue put-resource-policy`. Si des autorisations Lake Formation existent déjà, assurez-vous d'inclure l'option `--enable-hybrid` avec la valeur `'TRUE'`.

Pour obtenir des exemples d'utilisation de cette commande, veuillez consulter [Exemples de politiques basées sur les ressources pour Glue AWS](#).

Créer un appel d'API intercompte

Tous AWS Glue Data Catalog les opérations ont un `CatalogId` champ. Si les autorisations requises ont été accordées pour activer l'accès intercompte, un utilisateur peut créer des appels d'API du catalogue de données intercompte. L'appelant effectue cette opération en transmettant l'ID de compte AWS cible dans `CatalogId` afin d'accéder à la ressource de ce compte de destination.

Si aucune `CatalogId` valeur n'est fournie, AWS Glue utilise par défaut le propre identifiant de compte de l'appelant, et l'appel n'est pas intercomptes.

Créez un appel ETL intercompte

Momentanée AWS Glue PySpark et Scala APIs ont un champ d'ID de catalogue. Si toutes les autorisations requises ont été accordées pour permettre l'accès entre comptes, une tâche ETL peut effectuer PySpark et Scala appeler des opérations d'API entre comptes en transmettant l'ID du AWS compte cible dans le champ ID du catalogue pour accéder aux ressources du catalogue de données d'un compte cible.

Si aucune valeur d'ID de catalogue n'est fournie, AWS Glue utilise par défaut le propre identifiant de compte de l'appelant, et l'appel n'est pas intercomptes.

Pour PySpark APIs ce support `catalog_id`, voir [GlueContext classe](#). Pour APIs ce support `ScalaCatalogId`, voir [AWS Glue Scala GlueContext APIs](#).

L'exemple suivant montre les autorisations requises par le bénéficiaire pour exécuter une tâche ETL. Dans cet exemple, *grantee-account-id* est `catalog-id` le client qui exécute le travail et *grantor-account-id* le propriétaire de la ressource. Cet exemple accorde l'autorisation à toutes les ressources de catalogue dans le compte du concédant. Pour limiter l'étendue des ressources accordées, vous pouvez fournir des informations spécifiques au catalogue, ARNs à la base de données, à la table et à la connexion.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:GetConnection",
        "glue:GetDatabase",
        "glue:GetTable",
        "glue:GetPartition"
      ],
      "Principal": {"AWS": ["arn:aws:iam::grantee-account-id:root"]},
      "Resource": [
        "arn:aws:glue:us-east-1:grantor-account-id:"
      ]
    }
  ]
}
```

Note

Si la table dans le compte du concédant pointe vers un emplacement Amazon S3, qui est également dans le compte du concédant, le rôle IAM utilisé pour exécuter une tâche ETL dans le compte du concédant doit avoir l'autorisation de répertorier et d'obtenir les objets à partir du compte du concédant.

Étant donné que le client du Compte A est déjà autorisé à créer et exécuter des tâches ETL, les étapes élémentaires de configuration d'une tâche ETL pour l'accès intercompte sont les suivantes :

1. Autorisez l'accès intercompte aux données (ignorez cette étape si l'accès intercompte Amazon S3 est déjà configuré).
 - a. Mettez à jour la politique de compartiment Amazon S3 du compte B pour autoriser un accès intercompte à partir du compte A.
 - b. Mettez à jour la politique IAM du compte A pour autoriser l'accès au compartiment du Compte B.
2. Autoriser l'accès intercompte aux catalogues de données.

- a. Créez ou mettez à jour la politique de ressource attachée au catalogue de données dans le compte B pour autoriser l'accès depuis le compte A.
- b. Mettez à jour la politique IAM du compte A pour autoriser l'accès au catalogue de données dans le compte B.

Journalisation entre comptes CloudTrail

Quand un AWS Glue La tâche d'extraction, de transformation et de chargement (ETL) accède aux données sous-jacentes d'une table de catalogue de données partagée via des autorisations AWS Lake Formation entre comptes. Il existe un comportement de AWS CloudTrail journalisation supplémentaire.

Aux fins de cette discussion, le AWS compte qui a partagé la table est le compte propriétaire, et le compte avec lequel la table a été partagée est le compte destinataire. Lorsqu'une tâche ETL du compte destinataire accède aux données de la table du compte propriétaire, l' CloudTrail événement d'accès aux données ajouté aux journaux du compte destinataire est copié dans les journaux du CloudTrail compte propriétaire. Cela permet aux comptes propriétaires de suivre les accès aux données par les différents comptes destinataires. Par défaut, les CloudTrail événements n'incluent pas d'identifiant principal lisible par l'homme (ARN principal). Un administrateur du compte destinataire peut choisir d'inclure l'ARN du principal dans les journaux.

Pour plus d'informations, consultez la section [CloudTrailConnexion entre comptes](#) dans le Guide du AWS Lake Formation développeur.

 consultez aussi

- [the section called “Journalisation et surveillance”](#)

Propriété et facturation des ressources intercomptes

Lorsqu'un utilisateur d'un AWS compte (compte A) crée une nouvelle ressource telle qu'une base de données dans un autre compte (compte B), cette ressource est alors détenue par le compte B, le compte sur lequel elle a été créée. L'administrateur du Compte B obtient automatiquement des autorisations complètes pour accéder à la nouvelle ressource, y compris la lecture, l'écriture et l'octroi d'autorisations d'accès à un compte tiers. L'utilisateur du Compte A peut accéder à la ressource qu'il vient de créer uniquement s'il dispose des autorisations appropriées accordées par le Compte B.

Les coûts de stockage et les autres coûts directement liés à la nouvelle ressource sont facturés au Compte B, le propriétaire de la ressource. Le coût des demandes de l'utilisateur qui a créé la ressource est facturé au compte du demandeur, le Compte A.

Pour plus d'informations sur AWS Glue facturation et tarification, voir [Comment fonctionne la AWS tarification](#).

Limitations des accès inter-comptes

AWS Glue l'accès entre comptes comporte les limites suivantes :

- Accès multicompte à AWS Glue n'est pas autorisé si vous avez créé des bases de données et des tables à l'aide d'Amazon Athena ou d'Amazon Redshift Spectrum avant le support d'une région pour AWS Glue et le compte du propriétaire de la ressource n'a pas migré le catalogue de données Amazon Athena vers AWS Glue. Vous pouvez consulter le statut actuel de la migration à l'aide du [GetCatalogImportStatus \(get_catalog_import_status\)](#). Pour plus de détails sur la migration d'un catalogue Athena vers AWS Glue, voir [Mise à niveau vers AWS Glue Data Catalog step-by-step](#) dans le guide de l'utilisateur d'Amazon Athena.
- L'accès intercompte est uniquement pris en charge pour les ressources du catalogue de données, y compris les bases de données, les tables, les fonctions définies par l'utilisateur et les connexions.
- L'accès entre comptes au catalogue de données depuis Athena nécessite que vous enregistrez le catalogue en tant que ressource DataCatalog d'Athena. Pour obtenir des instructions, consultez la section [Enregistrement d'un AWS Glue Data Catalog depuis un autre compte figurant](#) dans le guide de l'utilisateur d'Amazon Athena.

Résolution des problèmes d'identité et d'accès à AWS Glue

Utilisez les informations suivantes pour vous aider à diagnostiquer et à résoudre les problèmes courants que vous pouvez rencontrer lorsque vous travaillez avec AWS Glue et IAM.

Rubriques

- [Je ne suis pas autorisé à effectuer une action dans AWS Glue](#)
- [Je ne suis pas autorisé à effectuer iam : PassRole](#)
- [Je souhaite autoriser des personnes extérieures à moi Compte AWS à accéder à mes ressources AWS Glue](#)

Je ne suis pas autorisé à effectuer une action dans AWS Glue

Si vous recevez une erreur qui indique que vous n'êtes pas autorisé à effectuer une action, vos politiques doivent être mises à jour afin de vous permettre d'effectuer l'action.

L'exemple d'erreur suivant se produit quand l'utilisateur IAM `mateojackson` tente d'utiliser la console pour afficher des informations détaillées sur une ressource `my-example-widget` fictive, mais ne dispose pas des autorisations `glue:GetWidget` fictives.

```
User: arn:aws:iam::123456789012:user/mateojackson is not authorized to perform:
glue:GetWidget on resource: my-example-widget
```

Dans ce cas, la politique qui s'applique à l'utilisateur `mateojackson` doit être mise à jour pour autoriser l'accès à la ressource `my-example-widget` à l'aide de l'action `glue:GetWidget`.

Si vous avez besoin d'aide, contactez votre AWS administrateur. Votre administrateur vous a fourni vos informations d'identification de connexion.

Je ne suis pas autorisé à effectuer iam : PassRole

Si vous recevez un message d'erreur indiquant que vous n'êtes pas autorisé à effectuer l'action `iam:PassRole`, vos politiques doivent être mises à jour pour vous permettre de transmettre un rôle à AWS Glue.

Certains services AWS permettent de transmettre un rôle existant à ce service au lieu de créer un nouveau rôle de service ou un rôle lié à un service. Pour ce faire, un utilisateur doit disposer des autorisations nécessaires pour transmettre le rôle au service.

L'exemple d'erreur suivant se produit lorsqu'un utilisateur IAM nommé `marymajor` essaie d'utiliser la console pour effectuer une action dans AWS Glue. Toutefois, l'action nécessite que le service ait des autorisations accordées par un rôle de service. Mary ne dispose pas des autorisations nécessaires pour transférer le rôle au service.

```
User: arn:aws:iam::123456789012:user/marymajor is not authorized to perform:
iam:PassRole
```

Dans ce cas, les politiques de Mary doivent être mises à jour pour lui permettre d'exécuter l'action `iam:PassRole`.

Si vous avez besoin d'aide, contactez votre AWS administrateur. Votre administrateur vous a fourni vos informations d'identification de connexion.

Je souhaite autoriser des personnes extérieures à moi Compte AWS à accéder à mes ressources AWS Glue

Vous pouvez créer un rôle que les utilisateurs provenant d'autres comptes ou les personnes extérieures à votre organisation pourront utiliser pour accéder à vos ressources. Vous pouvez spécifier qui est autorisé à assumer le rôle. Pour les services qui prennent en charge les politiques basées sur les ressources ou les listes de contrôle d'accès (ACLs), vous pouvez utiliser ces politiques pour autoriser les utilisateurs à accéder à vos ressources.

Pour plus d'informations, consultez les éléments suivants :

- Pour savoir si AWS Glue prend en charge ces fonctionnalités, consultez [Comment AWS Glue fonctionne avec IAM](#).
- Pour savoir comment fournir l'accès à vos ressources sur celles Comptes AWS que vous possédez, consultez la section [Fournir l'accès à un utilisateur IAM dans un autre utilisateur Compte AWS que vous possédez](#) dans le Guide de l'utilisateur IAM.
- Pour savoir comment fournir l'accès à vos ressources à des tiers Comptes AWS, consultez la section [Fournir un accès à des ressources Comptes AWS détenues par des tiers](#) dans le guide de l'utilisateur IAM.
- Pour savoir comment fournir un accès par le biais de la fédération d'identité, consultez [Fournir un accès à des utilisateurs authentifiés en externe \(fédération d'identité\)](#) dans le Guide de l'utilisateur IAM.
- Pour en savoir plus sur la différence entre l'utilisation des rôles et des politiques basées sur les ressources pour l'accès intercompte, consultez [Accès intercompte aux ressources dans IAM](#) dans le Guide de l'utilisateur IAM.

AWS Lake Formation modèles de contrôle d'accès

AWS Glue 5.0 prend en charge deux modèles d'accès aux données via AWS Lake Formation :

Rubriques

- [Utilisation de AWS Glue with AWS Lake Formation pour un accès complet à la table](#)
- [Utiliser AWS Glue with AWS Lake Formation pour un contrôle d'accès précis](#)

Utilisation de AWS Glue with AWS Lake Formation pour un accès complet à la table

Présentation de l'accès complet aux tables

AWS Glue La version 5.0 prend en charge le contrôle de l'accès complet aux tables (FTA) dans Apache Spark en fonction de vos politiques définies dans AWS Lake Formation. Cette fonctionnalité permet d'effectuer des opérations de lecture et d'écriture à partir de vos tâches AWS Glue Spark sur des tables AWS Lake Formation enregistrées lorsque le rôle de tâche dispose d'un accès complet aux tables. FTA est idéal pour les cas d'utilisation qui doivent se conformer aux réglementations de sécurité au niveau des tables et prend en charge les fonctionnalités de Spark, notamment les ensembles de données distribués résilients (RDDs), les bibliothèques personnalisées et les fonctions définies par l'utilisateur (UDFs) avec des AWS Lake Formation tables.

Lorsqu'une tâche AWS Glue Spark est configurée pour un accès complet aux tables (FTA), les AWS Lake Formation informations d'identification sont utilisées pour accéder aux données read/write Amazon S3 relatives aux tables AWS Lake Formation enregistrées, tandis que les informations d'identification du rôle d'exécution de la tâche sont utilisées pour read/write les tables non enregistrées auprès AWS Lake Formation de celles-ci. Cette fonctionnalité active les opérations DML (Data Manipulation Language), notamment les instructions CREATE, ALTER, DELETE, UPDATE et MERGE INTO sur les tables Apache Hive et Iceberg.

Note

Passez en revue vos exigences et déterminez si le contrôle d'accès détaillé (FGAC) ou l'accès complet aux tables (FTA) répondent à vos besoins. Une seule méthode AWS Lake Formation d'autorisation peut être activée pour une AWS Glue tâche donnée. Une tâche ne peut pas exécuter simultanément Full Table Access (FTA) et Fine-Grained Access Control (FGAC).

Comment fonctionne Full-Table Access (FTA) sur AWS Glue

AWS Lake Formation propose deux approches pour le contrôle d'accès aux données : le contrôle d'accès détaillé (FGAC) et l'accès complet aux tables (FTA). Le FGAC fournit une sécurité renforcée grâce à un filtrage au niveau des colonnes, des lignes et des cellules, idéal pour les scénarios nécessitant des autorisations granulaires. FTA est idéal pour les scénarios de contrôle d'accès simples où vous avez besoin d'autorisations au niveau de la table. Il simplifie la mise en œuvre en

éliminant le besoin d'activer le mode d'accès détaillé, améliore les performances et réduit les coûts en évitant le pilote système et les exécuteurs du système, et prend en charge les opérations de lecture et d'écriture (y compris les commandes CREATE, ALTER, DELETE, UPDATE et MERGE INTO).

Dans la AWS Glue version 4.0, l'accès aux données AWS Lake Formation basé sur la GlueContext classe s'effectuait par le biais de la classe utilitaire fournie par AWS Glue. Dans la AWS Glue version 5.0, l'accès aux données AWS Lake Formation basé est disponible via Spark SQL natif, Spark DataFrames, et continue d'être pris en charge par le biais GlueContext de classes.

Mise en œuvre de l'accès complet aux tables

Étape 1 : activer l'accès complet à la table dans AWS Lake Formation

Pour utiliser le mode Full Table Access (FTA), vous devez autoriser les moteurs de requêtes tiers à accéder aux données sans que la balise de session IAM ne soit validée. AWS Lake Formation Pour l'activer, suivez les étapes de la section [Intégration des applications pour un accès complet aux tables](#).

Étape 2 : Configuration des autorisations IAM pour le rôle d'exécution des tâches

Pour accéder en lecture ou en écriture aux données sous-jacentes, en plus des AWS Lake Formation autorisations, un rôle d'exécution de tâche nécessite l'autorisation `lakeformation:GetDataAccess` IAM. Avec cette autorisation, AWS Lake Formation accorde la demande d'informations d'identification temporaires pour accéder aux données.

Voici un exemple de politique expliquant comment fournir les autorisations IAM pour accéder à un script dans Amazon S3, le téléchargement de journaux sur Amazon S3, les autorisations d' AWS Glue API et les autorisations d'accès. AWS Lake Formation

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "ScriptAccess",
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ],
      "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket/scripts/*"
      ]
    }
  ],
}
```

```

{
  "Sid": "LoggingAccess",
  "Effect": "Allow",
  "Action": [
    "s3:PutObject"
  ],
  "Resource": [
    "arn:aws:s3:::amzn-s3-demo-bucket/logs/*"
  ]
},
{
  "Sid": "GlueCatalogAccess",
  "Effect": "Allow",
  "Action": [
    "glue:GetDatabase",
    "glue:GetDatabases",
    "glue:GetTable",
    "glue:GetTables",
    "glue:GetPartition",
    "glue:GetPartitions",
    "glue:CreateTable",
    "glue:UpdateTable"
  ],
  "Resource": [
    "arn:aws:glue:us-east-1:123456789012:catalog",
    "arn:aws:glue:us-east-1:123456789012:database/default",
    "arn:aws:glue:us-east-1:123456789012:table/default/*"
  ]
},
{
  "Sid": "LakeFormationAccess",
  "Effect": "Allow",
  "Action": [
    "lakeformation:GetDataAccess"
  ],
  "Resource": "*"
}
]
}

```

Étape 2.1 Configuration AWS Lake Formation des autorisations

AWS Glue Les tâches Spark qui lisent des données depuis Amazon S3 nécessitent l'autorisation AWS Lake Formation SELECT.

AWS Glue Spark Jobs pour write/delete lesquels les données d'Amazon S3 nécessitent AWS Lake Formation TOUTES les autorisations.

AWS Glue Les tâches Spark qui interagissent avec le catalogue de AWS Glue données nécessitent les autorisations DESCRIBE, ALTER, DROP, selon le cas.

Étape 3 : Initialisation d'une session Spark pour un accès complet à la table à l'aide de AWS Lake Formation

Pour accéder aux tables enregistrées auprès de Spark AWS Lake Formation, les configurations suivantes doivent être définies lors de l'initialisation de Spark afin que Spark utilise les AWS Lake Formation informations d'identification.

Pour accéder aux tables enregistrées auprès de vous AWS Lake Formation, vous devez configurer explicitement votre session Spark pour utiliser les AWS Lake Formation informations d'identification. Ajoutez les configurations suivantes lors de l'initialisation de votre session Spark :

```
from pyspark.sql import SparkSession

# Initialize Spark session with Lake Formation configurations
spark = SparkSession.builder \
    .appName("Lake Formation Full Table Access") \
    .config("spark.sql.catalog.glue_catalog",
"org.apache.spark.sql.catalog.hive.GlueCatalog") \
    .config("spark.sql.catalog.glue_catalog.glue.lakeformation-enabled", "true") \
    .config("spark.sql.defaultCatalog", "glue_catalog") \
    .getOrCreate()
```

Configurations principales :

- `spark.sql.catalog.glue_catalog`: Enregistre un catalogue nommé « `glue_catalog` » qui utilise l'implémentation `GlueCatalog`
- `spark.sql.catalog.glue_catalog.glue.lakeformation-enabled`: active explicitement AWS Lake Formation l'intégration pour ce catalogue
- Le nom du catalogue (« `glue_catalog` » dans cet exemple) peut être personnalisé, mais il doit être cohérent dans les deux paramètres de configuration

Hive

```
--conf spark.hadoop.fs.s3.credentialsResolverClass=com.amazonaws.AWS  
Glue.accesscontrol.AWSLakeFormationCredentialResolver  
--conf spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true  
--conf spark.hadoop.fs.s3.folderObject.autoAction.disabled=true  
--conf spark.sql.catalog.skipLocationValidationOnCreateTable.enabled=true  
--conf spark.sql.catalog.createDirectoryAfterTable.enabled=true  
--conf spark.sql.catalog.dropDirectoryBeforeTable.enabled=true
```

Iceberg

```
--conf spark.hadoop.fs.s3.credentialsResolverClass=com.amazonaws.AWS  
Glue.accesscontrol.AWSLakeFormationCredentialResolver  
--conf spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true  
--conf spark.hadoop.fs.s3.folderObject.autoAction.disabled=true  
--conf spark.sql.catalog.skipLocationValidationOnCreateTable.enabled=true  
--conf spark.sql.catalog.createDirectoryAfterTable.enabled=true  
--conf spark.sql.catalog.dropDirectoryBeforeTable.enabled=true  
--conf spark.sql.catalog.<catalog>.AWS Glue.lakeformation-enabled=true
```

- `spark.hadoop.fs.s3.credentialsResolverClass=com.amazonaws.AWS Glue.accesscontrol.AWSLakeFormationCredentialResolver`: Configurez le système de fichiers EMR (EMRFS) pour utiliser les informations d'identification AWS Lake Formation S3 pour les tables enregistrées. AWS Lake Formation Si la table n'est pas enregistrée, utilisez les informations d'identification du rôle d'exécution de la tâche.
- `spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true` et `spark.hadoop.fs.s3.folderObject.autoAction.disabled=true` : Configurez EMRFS pour utiliser l'en-tête de type de contenu application/x-directory au lieu du suffixe `$folder$` lors de la création de dossiers S3. Cela est nécessaire lors de la lecture de AWS Lake Formation tables, car les AWS Lake Formation informations d'identification ne permettent pas de lire les dossiers de tables portant le suffixe `$folder$`.
- `spark.sql.catalog.skipLocationValidationOnCreateTable.enabled=true`: configurez Spark pour qu'il ignore la validation de l'emplacement vide de la table avant sa création. Cela est nécessaire pour les tables AWS Lake Formation enregistrées, car les AWS

Lake Formation informations d'identification permettant de vérifier l'emplacement vide ne sont disponibles qu'après la création de la table du catalogue de AWS Glue données. Sans cette configuration, les informations d'identification du rôle d'exécution de la tâche valideront l'emplacement de la table vide.

- `spark.sql.catalog.createDirectoryAfterTable.enabled=true`: configurez Spark pour créer le dossier Amazon S3 après la création de la table dans le métastore Hive. Cela est obligatoire pour les tables AWS Lake Formation enregistrées, car les AWS Lake Formation informations d'identification permettant de créer le dossier Amazon S3 ne sont disponibles qu'après la création de la table du catalogue de AWS Glue données.
- `spark.sql.catalog.dropDirectoryBeforeTable.enabled=true`: configurez Spark pour qu'il supprime le dossier Amazon S3 avant de supprimer la table dans le métastore Hive. Cela est nécessaire pour les tables AWS Lake Formation enregistrées, car les AWS Lake Formation informations d'identification permettant de supprimer le dossier S3 ne sont pas disponibles après la suppression des tables du catalogue de AWS Glue données.
- `spark.sql.catalog.<catalog>.AWS Glue.lakeformation-enabled=true`: configurez le catalogue Iceberg pour utiliser les informations d'identification AWS Lake Formation Amazon S3 pour les tables AWS Lake Formation enregistrées. Si la table n'est pas enregistrée, utilisez les informations d'identification d'environnement par défaut.

Schémas d'utilisation

Utiliser FTA avec DataFrames

Pour les utilisateurs habitués à Spark, il DataFrames peut être utilisé avec AWS Lake Formation Full Table Access.

AWS Glue La version 5.0 ajoute le support natif de Spark pour l'accès complet aux tables de Lake Formation, simplifiant ainsi la façon dont vous travaillez avec les tables protégées. Cette fonctionnalité permet aux tâches AWS Glue Spark AWS Glue 5.0 de lire et d'écrire directement des données lorsque l'accès complet à la table est accordé, supprimant ainsi les limitations qui limitaient auparavant certaines opérations d'extraction, de transformation et de chargement (ETL). Vous pouvez désormais tirer parti des fonctionnalités avancées de Spark, notamment des ensembles de données distribués résilients (RDDs), des bibliothèques personnalisées et des fonctions définies par l'utilisateur (UDFs) avec des AWS Lake Formation tables.

Native Spark FTA en version 5.0 AWS Glue

AWS Glue La version 5.0 prend en charge le contrôle d'accès aux tables complètes (FTA) dans Apache Spark en fonction de vos politiques définies dans AWS Lake Formation Ce niveau de contrôle est idéal pour les cas d'utilisation qui doivent être conformes aux réglementations de sécurité au niveau de la table.

Exemple de table Apache Iceberg

```
from pyspark.sql import SparkSession

catalog_name = "spark_catalog"
aws_region = "us-east-1"
aws_account_id = "123456789012"
warehouse_path = "s3://amzn-s3-demo-bucket/warehouse/"

spark = SparkSession.builder \

    .config("spark.sql.extensions", "org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions") \
    .config(f"spark.sql.catalog.{catalog_name}",
            "org.apache.iceberg.spark.SparkSessionCatalog") \
    .config(f"spark.sql.catalog.{catalog_name}.warehouse", f"{warehouse_path}") \
    .config(f"spark.sql.catalog.{catalog_name}.client.region", f"{aws_region}") \
    .config(f"spark.sql.catalog.{catalog_name}.glue.account-id", f"{aws_account_id}") \
    .config(f"spark.sql.catalog.{catalog_name}.glue.lakeformation-enabled", "true") \
    .config(f"spark.sql.catalog.dropDirectoryBeforeTable.enabled", "true") \
    .config(f"spark.sql.catalog.{catalog_name}.catalog-impl",
            "org.apache.iceberg.aws.glue.GlueCatalog") \
    .config(f"spark.sql.catalog.{catalog_name}.io-impl",
            "org.apache.iceberg.aws.s3.S3FileIO") \
    .config("spark.sql.defaultCatalog", catalog_name) \ # Add this line
    .getOrCreate()

database_name = "your_database"
table_name = "your_table"

df = spark.sql(f"select * from {database_name}.{table_name}")
df.show()
```

Autorisations IAM nécessaires

Votre rôle AWS Glue d'exécution de tâches doit comporter les éléments suivants :

```
{  
  "Action": "lakeformation:GetDataAccess",  
  "Resource": "*",  
  "Effect": "Allow"  
}
```

Sans oublier les autorisations d'accès S3 appropriées pour l'emplacement de vos données.

Configuration de la formation du lac

Avant d'utiliser Spark FTA natif dans la AWS Glue version 5.0 :

1. Autoriser les moteurs de requêtes tiers à accéder aux données sans validation des balises de session IAM dans AWS Lake Formation
2. Accordez les autorisations de table appropriées à votre AWS Glue rôle d'exécution de tâches via AWS Lake Formation la console
3. Configurez votre session Spark avec les paramètres requis indiqués dans l'exemple ci-dessus

Utiliser FTA avec DynamicFrames

AWS Glue DynamicFrames peut être utilisé avec AWS Lake Formation Full Table Access pour des opérations ETL optimisées. L'accès complet aux tables (FTA) fournit un modèle de sécurité qui accorde des autorisations au niveau de la table, ce qui permet un traitement des données plus rapide que le contrôle d'accès détaillé (FGAC), car il permet d'éviter les surcharges liées aux vérifications d'autorisation au niveau des lignes et des colonnes. Cette approche est utile lorsque vous devez traiter des tables entières et que les autorisations au niveau des tables répondent à vos exigences de sécurité.

Dans la AWS Glue version 4.0, DynamicFrames FTA nécessitait une GlueContext configuration spécifique. Alors que le DynamicFrame code AWS Glue 4.0 existant avec FTA continuera de fonctionner dans la version AWS Glue 5.0, la nouvelle version offre également un support natif de Spark FTA avec une plus grande flexibilité. Pour les nouveaux développements, pensez à utiliser l'approche native de Spark décrite dans la DataFrames section, en particulier si vous avez besoin de fonctionnalités supplémentaires telles que des ensembles de données distribués résilients (RDDs), des bibliothèques personnalisées et des fonctions définies par l'utilisateur (UDFs) avec des AWS Lake Formation tables.

Autorisations nécessaires

Le rôle IAM exécutant votre tâche Glue doit avoir :

- `lakeformation:GetDataAccess` autorisation
- Permissions de table Lake Formation appropriées accordées via la console Lake Formation

Exemple de DynamicFrame mise en œuvre dans la AWS Glue version 5.0

```
from awsglue.context import GlueContext
from pyspark.context import SparkContext

# Initialize Glue context
sc = SparkContext()
glueContext = GlueContext(sc)

# Configure catalog for Iceberg tables
catalog_name = "glue_catalog"
aws_region = "us-east-1"
aws_account_id = "123456789012"
warehouse_path = "s3://amzn-s3-demo-bucket/warehouse/"

spark = glueContext.spark_session
spark.conf.set(f"spark.sql.catalog.{catalog_name}",
               "org.apache.iceberg.spark.SparkCatalog")
spark.conf.set(f"spark.sql.catalog.{catalog_name}.warehouse", f"{warehouse_path}")
spark.conf.set(f"spark.sql.catalog.{catalog_name}.catalog-impl",
               "org.apache.iceberg.aws.glue.GlueCatalog")
spark.conf.set(f"spark.sql.catalog.{catalog_name}.io-impl",
               "org.apache.iceberg.aws.s3.S3FileIO")
spark.conf.set(f"spark.sql.catalog.{catalog_name}.glue.lakeformation-enabled", "true")
spark.conf.set(f"spark.sql.catalog.{catalog_name}.client.region", f"{aws_region}")
spark.conf.set(f"spark.sql.catalog.{catalog_name}.glue.id", f"{aws_account_id}")

# Read Lake Formation-protected table with DynamicFrame
df = glueContext.create_data_frame.from_catalog(
    database="your_database",
    table_name="your_table"
)
```


Configuration supplémentaire

Configurer le mode d'accès complet aux tables dans les AWS Glue Studio blocs-notes

Pour accéder aux tables AWS Lake Formation enregistrées à partir de sessions Spark interactives dans des AWS Glue Studio blocs-notes, vous devez utiliser le mode d'autorisation de compatibilité. Utilisez la commande `%%configure` magique pour configurer votre configuration Spark avant de démarrer votre session interactive. Cette configuration doit être la première commande de votre bloc-notes, car elle ne peut pas être appliquée une fois la session démarrée. Choisissez la configuration en fonction de votre type de table :

Pour les tables Hive

```
%%configure
--conf
  spark.hadoop.fs.s3.credentialsResolverClass=com.amazonaws.glue.accesscontrol.AWSLakeFormationC
--conf spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true
--conf spark.hadoop.fs.s3.folderObject.autoAction.disabled=true
--conf spark.sql.catalog.skipLocationValidationOnCreateTable.enabled=true
--conf spark.sql.catalog.createDirectoryAfterTable.enabled=true
--conf spark.sql.catalog.dropDirectoryBeforeTable.enabled=true
```

Pour les tables Iceberg

```
%%configure
--conf
  spark.hadoop.fs.s3.credentialsResolverClass=com.amazonaws.glue.accesscontrol.AWSLakeFormationC
--conf spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true
--conf spark.hadoop.fs.s3.folderObject.autoAction.disabled=true
--conf spark.sql.catalog.skipLocationValidationOnCreateTable.enabled=true
--conf spark.sql.catalog.createDirectoryAfterTable.enabled=true
--conf spark.sql.catalog.dropDirectoryBeforeTable.enabled=true
--conf spark.sql.catalog.glue_catalog.glue.lakeformation-enabled=true
--conf spark.sql.catalog.glue_catalog.warehouse=s3://example-s3-bucket_DATA_LOCATION
--conf spark.sql.catalog.glue_catalog.catalog-
impl=org.apache.iceberg.aws.glue.GlueCatalog
--conf spark.sql.catalog.glue_catalog.io-impl=org.apache.iceberg.aws.s3.S3FileIO
--conf spark.sql.catalog.glue_catalog.glue.account-id=ACCOUNT_ID
--conf spark.sql.catalog.glue_catalog.glue.region=REGION
```

Remplacez les espaces réservés :

- S3_DATA_LOCATION : *s3://amzn-s3-demo-bucket*
- RÉGION : *AWS Region (e.g., us-east-1)*
- IDENTIFIANT DU COMPTE : *Your AWS Account ID*

 Note

Vous devez définir ces configurations avant d'exécuter des opérations Spark dans votre bloc-notes.

Opérations prises en charge

Ces opérations utiliseront des AWS Lake Formation informations d'identification pour accéder aux données de la table.

 Note

Lors de l'activation AWS Lake Formation :

- Pour FTA : activer la configuration Spark `spark.sql.catalog.{catalog_name}.glue.lakeformation-enabled`

- CREATE TABLE
- ALTER TABLE
- INSERT INTO
- INSERT OVERWRITE
- SELECT
- UPDATE
- MERGE INTO
- DELETE FROM
- ANALYSER LE TABLEAU
- TABLE DE RÉPARATION
- DROP TABLE

- Requêtes de source de données Spark
- Écritures de source de données Spark

Note

Les opérations non répertoriées ci-dessus continueront à utiliser les autorisations IAM pour accéder aux données des tables.

Migration de la AWS Glue version 4.0 à la version AWS Glue 5.0 FTA

Lors de la migration de la AWS Glue version 4.0 GlueContext FTA vers la AWS Glue version 5.0 native de Spark FTA :

1. Autorisez les moteurs de requêtes tiers à accéder aux données sans la validation de la balise de session IAM dans AWS Lake Formation. Suivez [Étape 1 : activer l'accès complet à la table dans AWS Lake Formation](#).
2. Il n'est pas nécessaire de modifier le rôle d'exécution des tâches. Vérifiez toutefois que le rôle AWS Glue d'exécution de la tâche dispose de l'autorisation lakeformation : GetDataAccess IAM.
3. Modifiez les configurations de session Spark dans le script. Assurez-vous que les configurations Spark suivantes sont présentes :

```
--conf spark.sql.catalog.spark_catalog=org.apache.iceberg.spark.SparkSessionCatalog
--conf spark.sql.catalog.spark_catalog.warehouse=s3://<bucket-name>/warehouse/
--conf spark.sql.catalog.spark_catalog.client.region=<REGION>
--conf spark.sql.catalog.spark_catalog.glue.account-id=ACCOUNT_ID
--conf spark.sql.catalog.spark_catalog.glue.lakeformation-enabled=true
--conf spark.sql.catalog.dropDirectoryBeforeTable.enabled=true
```

4. Mettez à jour le script tel qu' GlueContext DataFrames il est remplacé par Native Spark DataFrames.
5. Mettez à jour votre AWS Glue tâche pour utiliser la AWS Glue version 5.0

Considérations et restrictions

- Si une table Hive est créée à l'aide d'une tâche pour laquelle l'accès complet à la table n'est pas activé et qu'aucun enregistrement n'est inséré, les lectures ou écritures suivantes à partir d'une

tâche avec accès complet à la table échoueront. Cela est dû au fait que AWS Glue Spark sans accès complet à la table ajoute le suffixe \$folder\$ au nom du dossier de la table. Pour résoudre ce problème, vous pouvez soit :

- Insérez au moins une ligne dans le tableau à partir d'une tâche pour laquelle FTA n'est pas activé.
- Configurez la tâche pour laquelle FTA n'est pas activé pour ne pas utiliser le suffixe \$folder\$ dans le nom du dossier dans S3. Cela peut être réalisé en définissant la configuration de `Sparkspark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true`.
- Créez un dossier Amazon S3 à l'emplacement de la table à `s3://path/to/table/table_name` l'aide de la console Amazon S3 ou de la CLI Amazon S3.
- Full Table Access fonctionne exclusivement avec le système de fichiers EMR (EMRFS). Le système de fichiers S3A n'est pas compatible.
- L'accès complet aux tables est pris en charge pour les tables Hive et Iceberg. Support pour les tables Hudi et Delta n'a pas encore été ajouté.
- Les tâches faisant référence à des tables dotées de règles de contrôle d' AWS Lake Formation accès fin (FGAC) ou à des vues de catalogue de AWS Glue données échoueront. Pour interroger une table avec des règles FGAC ou une vue de catalogue de AWS Glue données, vous devez utiliser le mode FGAC. Vous pouvez activer le mode FGAC en suivant les étapes décrites dans la AWS documentation : Utilisation AWS Glue avec AWS Lake Formation pour un contrôle d'accès précis.
- L'accès complet aux tables ne prend pas en charge Spark Streaming.
- Ne peut pas être utilisé simultanément avec le FGAC.

Utiliser AWS Glue with AWS Lake Formation pour un contrôle d'accès précis

Présentation

Avec AWS la version 5.0 et les versions ultérieures de Glue, vous pouvez AWS Lake Formation appliquer des contrôles d'accès précis aux tables du catalogue de données soutenues par S3. Cette fonctionnalité vous permet de configurer des contrôles d'accès au niveau des tables, des lignes, des colonnes et des cellules pour les read requêtes contenues dans vos tâches AWS Glue for Apache Spark. Consultez les sections suivantes pour en savoir plus sur Lake Formation et sur son utilisation avec AWS Glue.

GlueContext contrôle d'accès basé sur une table avec des AWS Lake Formation autorisations prises en charge dans Glue 4.0 ou antérieur n'est pas pris en charge dans Glue 5.0. Utilisez le nouveau contrôle d'accès fin natif de Spark (FGAC) dans Glue 5.0. Notez les informations suivantes :


- Si vous avez besoin d'un contrôle d'accès détaillé (FGAC) pour le contrôle row/column/cell d'accès, vous devez migrer depuis GlueContext DynamicFrame /Glue dans Glue 4.0 et avant le dataframe Spark dans Glue 5.0. Pour obtenir des exemples, consultez [Migration de Spark GlueContext/Glue DynamicFrame vers Spark DataFrame](#)
- Si vous avez besoin d'un contrôle d'accès complet aux tables (FTA), vous pouvez tirer parti du FTA dans DynamicFrames Glue 5.0. Vous pouvez également migrer vers l'approche native de Spark pour bénéficier de fonctionnalités supplémentaires telles que les ensembles de données distribués résilients (RDDs), les bibliothèques personnalisées et les fonctions définies par l'utilisateur (UDFs) avec des AWS Lake Formation tables. Pour des exemples, voir [Migration de AWS Glue 4.0 vers AWS Glue 5.0 FTA](#).
- Si vous n'avez pas besoin du FGAC, aucune migration vers le dataframe Spark n'est nécessaire et les GlueContext fonctionnalités telles que les signets de tâches et les prédicats push down continueront de fonctionner.
- Les tâches au sein du FGAC nécessitent un minimum de 4 travailleurs : un pilote utilisateur, un pilote système, un exécuteur système et un exécuteur utilisateur de secours.

L'utilisation AWS de Glue with AWS Lake Formation entraîne des frais supplémentaires.

Comment fonctionne AWS Glue avec AWS Lake Formation

L'utilisation de AWS Glue with Lake Formation vous permet d'appliquer une couche d'autorisations à chaque tâche Spark afin d'appliquer le contrôle des autorisations de Lake Formation lorsque AWS Glue exécute des tâches. AWS Glue utilise les [profils de ressources Spark](#) pour créer deux profils afin d'exécuter efficacement les tâches. Le profil utilisateur exécute le code fourni par l'utilisateur, tandis que le profil système applique les politiques de Lake Formation. Pour plus d'informations, voir [Qu'est-ce que c'est](#), [Considérations AWS Lake Formation et limites](#).

Voici un aperçu général de la manière dont AWS Glue accède aux données protégées par les politiques de sécurité de Lake Formation.



1. Un utilisateur appelle l'`StartJobRunAPI` sur une tâche AWS Glue compatible avec AWS Lake Formation.
2. AWS Glue envoie la tâche à un pilote utilisateur et l'exécute dans le profil utilisateur. Le pilote utilisateur exécute une version allégée de Spark qui n'est pas en mesure de lancer des tâches, de demander des exécuteurs, d'accéder à S3 ou au catalogue Glue. Il élabore un plan d'emploi.
3. AWS Glue configure un deuxième pilote appelé pilote système et l'exécute dans le profil système (avec une identité privilégiée). AWS Glue met en place un canal TLS crypté entre les deux pilotes pour la communication. Le pilote utilisateur utilise le canal pour envoyer les plans de travail au pilote du système. Le pilote du système n'exécute pas le code envoyé par l'utilisateur.

Il exécute Spark dans son intégralité et communique avec S3 et le catalogue de données pour l'accès aux données. Il demande des exécuteurs et compile le Job Plan en une séquence d'étapes d'exécution.

4. AWS Glue exécute ensuite les étapes sur les exécuteurs avec le pilote utilisateur ou le pilote système. À n'importe quel stade, le code utilisateur est exécuté exclusivement sur les exécuteurs de profil utilisateur.
5. Les étapes qui lisent les données des tables du catalogue de données protégées par des filtres de sécurité AWS Lake Formation ou qui appliquent des filtres de sécurité sont déléguées aux exécuteurs du système.

Exigence minimale de travailleurs

Une tâche compatible avec Lake Formation dans AWS Glue nécessite un minimum de 4 travailleurs : un pilote utilisateur, un pilote système, un exécuteur système et un exécuteur utilisateur de secours. Cela représente une augmentation par rapport au minimum de 2 travailleurs requis pour les travaux standard de AWS Glue.

Une tâche compatible avec Lake Formation dans AWS Glue utilise deux pilotes Spark, l'un pour le profil système et l'autre pour le profil utilisateur. De même, les exécuteurs sont également divisés en deux profils :

- Exécuteurs du système : gèrent les tâches auxquelles les filtres de données de Lake Formation sont appliqués.
- Exécuteurs utilisateur : sont demandés par le pilote du système selon les besoins.

Comme les jobs de Spark sont par nature paresseux, AWS Glue réserve 10 % du nombre total de travailleurs (minimum 1), après déduction des deux facteurs, aux exécuteurs utilisateurs.

L'auto-scaling est activé pour toutes les tâches compatibles avec Lake Formation, ce qui signifie que les exécuteurs utilisateurs ne démarrent qu'en cas de besoin.

Pour un exemple de configuration, consultez la section [Considérations et limites](#).

Autorisations IAM du rôle d'exécution des tâches

Les autorisations de Lake Formation contrôlent l'accès aux ressources du catalogue de données AWS Glue, aux sites Amazon S3 et aux données sous-jacentes de ces sites. Les autorisations

IAM contrôlent l'accès à la Lake Formation and AWS Glue APIs et aux ressources. Bien que vous ayez l'autorisation Lake Formation d'accéder à une table du catalogue de données (SELECT), votre opération échoue si vous ne disposez pas de l'autorisation IAM pour l'opération d'glue: Get*API.

Voici un exemple de politique expliquant comment fournir des autorisations IAM pour accéder à un script dans S3, télécharger des journaux dans S3, autoriser l'API AWS Glue et accéder à Lake Formation.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "ScriptAccess",
      "Effect": "Allow",
      "Action": [
        "s3:GetObject",
        "s3:ListBucket"
      ],
      "Resource": [
        "arn:aws:s3::*.amzn-s3-demo-bucket/scripts",
        "arn:aws:s3::*.amzn-s3-demo-bucket/*" ]
    },
    {
      "Sid": "LoggingAccess",
      "Effect": "Allow",
      "Action": [
        "s3:PutObject"
      ],
      "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket/logs/*"
      ]
    },
    {
      "Sid": "GlueCatalogAccess",
      "Effect": "Allow",
      "Action": [
        "glue:Get*",
        "glue:Create*",
        "glue:Update*"
      ],
      "Resource": ["*"]
    }
  ],
  {
```



```
        "Sid": "LakeFormationAccess",
        "Effect": "Allow",
        "Action": [
            "lakeformation:GetDataAccess"
        ],
        "Resource": ["*"]
    }
}
```

Configuration des autorisations de Lake Formation pour le rôle d'exécution des tâches

Tout d'abord, enregistrez l'emplacement de votre table Hive avec Lake Formation. Créez ensuite des autorisations pour votre rôle d'exécution des tâches dans le tableau de votre choix. Pour plus de détails sur Lake Formation, voir [Qu'est-ce que c'est AWS Lake Formation ?](#) dans le Guide AWS Lake Formation du développeur.

Après avoir configuré les autorisations de Lake Formation, vous pouvez soumettre des jobs Spark sur AWS Glue.

Soumission d'une exécution de tâche

Une fois que vous aurez fini de configurer les subventions Lake Formation, vous pourrez soumettre des jobs Spark sur AWS Glue. Pour exécuter des tâches Iceberg, vous devez fournir les configurations Spark suivantes. Pour configurer via les paramètres de la tâche Glue, entrez le paramètre suivant :

- Clé :

```
--conf
```

- Valeur :

```
spark.sql.catalog.spark_catalog=org.apache.iceberg.spark.SparkSessionCatalog
--conf spark.sql.catalog.spark_catalog.warehouse=<S3_DATA_LOCATION>
--conf spark.sql.catalog.spark_catalog.glue.account-id=<ACCOUNT_ID>
--conf spark.sql.catalog.spark_catalog.client.region=<REGION>
--conf spark.sql.catalog.spark_catalog.glue.endpoint=https://
glue.<REGION>.amazonaws.com
```

Utilisation d'une session interactive

Une fois que vous avez fini de configurer les AWS Lake Formation subventions, vous pouvez utiliser Interactive Sessions on AWS Glue. Vous devez fournir les configurations Spark suivantes par `%configure` magie avant d'exécuter le code.

```
%%configure
{
  "--enable-lakeformation-fine-grained-access": "true",
  "--conf":
  "spark.sql.catalog.spark_catalog=org.apache.iceberg.spark.SparkSessionCatalog
  --conf spark.sql.catalog.spark_catalog.warehouse=<S3_DATA_LOCATION> --conf
  spark.sql.catalog.spark_catalog.catalog-impl=org.apache.iceberg.aws.glue.GlueCatalog
  --conf spark.sql.catalog.spark_catalog.io-impl=org.apache.iceberg.aws.s3.S3FileIO --
  conf
  spark.sql.extensions=org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions
  --conf spark.sql.catalog.spark_catalog.client.region=<REGION> --conf
  spark.sql.catalog.spark_catalog.glue.account-id=<ACCOUNT_ID> --conf
  spark.sql.catalog.spark_catalog.glue.endpoint=https://glue.<REGION>.amazonaws.com"
}
```

FGAC for AWS Glue 5.0 Notebook ou sessions interactives

Pour activer le contrôle d'accès fin (FGAC) dans AWS Glue, vous devez spécifier les configurations Spark requises pour Lake Formation dans le cadre de la magie de `%%configure` avant de créer la première cellule.

Le spécifier ultérieurement à l'aide des appels `SparkSession.builder().conf("").get()` ou `SparkSession.builder().conf("").create()` suffira pas. Il s'agit d'une modification par rapport au comportement de AWS Glue 4.0.

Support du format de tableau ouvert

AWS La version 5.0 ou ultérieure de Glue inclut la prise en charge d'un contrôle d'accès précis basé sur Lake Formation. AWS Glue est compatible avec les tables de type Hive et Iceberg. Le tableau suivant décrit toutes les opérations prises en charge.

Opérations	Hive	Iceberg
Commandes DML	Avec des autorisations de rôle IAM uniquement	Avec des autorisations de rôle IAM uniquement

Opérations	Hive	Iceberg
Requêtes progressives	Ne s'applique pas	Entièrement pris en charge
Requêtes Time Travel	Non applicable à ce format de tableau	Entièrement pris en charge
Tables de métadonnées	Non applicable à ce format de tableau	Supporté, mais certaines tables sont masquées. Consultez les considérations et les limites pour plus d'informations.
DML INSERT	Avec des autorisations IAM uniquement	Avec des autorisations IAM uniquement
MISE À JOUR DML	Non applicable à ce format de tableau	Avec des autorisations IAM uniquement
DML DELETE	Non applicable à ce format de tableau	Avec des autorisations IAM uniquement
Opérations de lecture	Entièrement pris en charge	Entièrement pris en charge
Procédures stockées	Ne s'applique pas	Pris en charge à l'exception de <code>register_table</code> et <code>migrate</code> . Consultez les considérations et les limites pour plus d'informations.

Migration de Spark GlueContext/Glue DynamicFrame vers Spark DataFrame

Vous trouverez ci-dessous des exemples de migration de GlueContext /Glue in Glue 4.0 vers Spark in DynamicFrame Glue 5.0 en DataFrame Python et Scala.

Python

Avant :

```

escaped_table_name= '`<dbname>`.`<table_name>`'

additional_options = {
    "query": f'select * from {escaped_table_name} WHERE column1 = 1 AND column7 = 7'
}

# DynamicFrame example
dataset = glueContext.create_data_frame_from_catalog(
    database="<dbname>",
    table_name=escaped_table_name,
    additional_options=additional_options)

```

Après :

```

table_identifier= '`<catalogname>`.`<dbname>`.`<table_name>`' #catalogname is optional

# DataFrame example
dataset = spark.sql(f'select * from {table_identifier} WHERE column1 = 1 AND column7 = 7')

```

Scala

Avant :

```

val escapedTableName = "`<dbname>`.`<table_name>`"

val additionalOptions = JsonOptions(Map(
    "query" -> s"select * from $escapedTableName WHERE column1 = 1 AND column7 = 7"
))

# DynamicFrame example
val datasource0 = glueContext.getCatalogSource(
    database="<dbname>",
    tableName=escapedTableName,
    additionalOptions=additionalOptions).getDataFrame()

```

Après :

```

val tableIdentifier = "`<catalogname>`.`<dbname>`.`<table_name>`" //catalogname is optional

```

```
# DataFrame example
val datasource0 = spark.sql(s"select * from $tableIdentifier WHERE column1 = 1 AND
column7 = 7")
```

Considérations et restrictions

Tenez compte des considérations et limites suivantes lorsque vous utilisez Lake Formation with AWS Glue.

AWS Glue with Lake Formation est disponible dans toutes les régions prises en charge, à l'exception de AWS GovCloud (USA Est) et AWS GovCloud (USA Ouest).

- AWS Glue permet un contrôle d'accès précis via Lake Formation uniquement pour les tables Apache Hive et Apache Iceberg. Les formats Apache Hive incluent Parquet, ORC et CSV.
- Vous ne pouvez utiliser Lake Formation qu'avec des tâches Spark.
- AWS Glue with Lake Formation ne prend en charge qu'une seule session Spark tout au long d'une tâche.
- Lorsque Lake Formation est activé, AWS Glue nécessite un plus grand nombre de travailleurs car il nécessite un pilote système, des exécuteurs système, un pilote utilisateur et éventuellement des exécuteurs utilisateur (requis lorsque votre tâche possède UDFs ou `spark.createDataFrame`).
- AWS Glue with Lake Formation ne prend en charge que les requêtes de table entre comptes partagées via des liens de ressources. Le lien de ressource doit être nommé de la même manière que la ressource du compte source.
- Pour activer un contrôle d'accès précis pour les tâches AWS Glue, transmettez le paramètre de la `--enable-lakeformation-fine-grained-access` tâche.
- Vous pouvez configurer vos jobs AWS Glue pour qu'ils fonctionnent avec la hiérarchie multi-catalogues AWS Glue. Pour plus d'informations sur les paramètres de configuration à utiliser avec l'`StartJobRunAPI` AWS Glue, consultez la section [Working with AWS Glue multi-catalogues sur EMR Serverless](#).
- Les éléments suivants ne sont pas pris en charge :
 - Ensembles de données distribués résilients (RDD)
 - Streaming Spark
 - Écrivez avec les autorisations accordées à Lake Formation
 - Contrôle d'accès pour les colonnes imbriquées
- AWS Glue bloque les fonctionnalités susceptibles de compromettre l'isolation complète du pilote système, notamment les suivantes :

- UDTs, Hive UDFs et toute fonction définie par l'utilisateur impliquant des classes personnalisées
- Sources de données personnalisées
- Fourniture de fichiers JAR supplémentaires pour l'extension, le connecteur ou le metastore Spark
- ANALYZE TABLE commande
- Pour appliquer les contrôles d'accès EXPLAIN PLAN et les opérations DDL telles que le fait de DESCRIBE TABLE ne pas exposer les informations restreintes.
- AWS Glue restreint l'accès aux journaux Spark du pilote système sur les applications compatibles avec Lake Formation. Étant donné que le pilote système s'exécute avec plus d'accès, les événements et les journaux générés par le pilote système peuvent inclure des informations sensibles. Pour empêcher les utilisateurs ou le code non autorisés d'accéder à ces données sensibles, AWS Glue a désactivé l'accès aux journaux des pilotes du système. Pour le dépannage, contactez AWS le support.
- Si vous avez enregistré l'emplacement d'une table auprès de Lake Formation, le chemin d'accès aux données passe par les informations d'identification stockées dans Lake Formation, indépendamment de l'autorisation IAM pour le rôle d'exécution de la tâche AWS Glue. Si vous configurez mal le rôle enregistré avec l'emplacement de la table, les tâches soumises qui utilisent le rôle avec l'autorisation S3 IAM sur l'emplacement de la table échoueront.
- L'écriture dans une table Lake Formation utilise l'autorisation IAM plutôt que les autorisations accordées par Lake Formation. Si votre rôle d'exécution de tâches dispose des autorisations S3 nécessaires, vous pouvez l'utiliser pour exécuter des opérations d'écriture.

Voici les considérations et limites relatives à l'utilisation d'Apache Iceberg :

- Vous ne pouvez utiliser Apache Iceberg qu'avec un catalogue de sessions et non avec des catalogues nommés arbitrairement.
- Les tables Iceberg enregistrées dans Lake Formation ne prennent en charge que les tables de métadonnées `historymetadata_log_entries`, `snapshots`, `filesmanifests`, et `refs`. AWS Glue masque les colonnes susceptibles de contenir des données sensibles, telles que `partitionspath`, et `summaries`. Cette limitation ne s'applique pas aux tables Iceberg qui ne sont pas enregistrées dans Lake Formation.
- Les tables que vous n'enregistrez pas dans Lake Formation prennent en charge toutes les procédures stockées par Iceberg. Les migrate procédures `register_table` et ne sont prises en charge pour aucune table.

- Nous vous recommandons d'utiliser Iceberg DataFrameWriter V2 au lieu de V1.

Exemple d'allocation des travailleurs

Pour une tâche configurée avec les paramètres suivants :

```
--enable-lakeformation-fine-grained-access=true  
--number-of-workers=20
```

La répartition des travailleurs serait la suivante :

- Un travailleur pour le pilote utilisateur.
- Un travailleur pour le pilote du système.
- 10 % des 18 travailleurs restants (soit 2 travailleurs) réservés aux exécuteurs utilisateurs.
- Jusqu'à 16 travailleurs affectés aux exécuteurs du système.

Lorsque l'auto-scaling est activé, les exécuteurs utilisateurs peuvent utiliser n'importe quelle capacité non allouée par les exécuteurs du système si nécessaire.

Contrôle de l'allocation des exécuteurs par utilisateur

Vous pouvez ajuster le pourcentage de réservation pour les exécuteurs utilisateurs à l'aide de la configuration suivante :

```
--conf spark.dynamicAllocation.maxExecutorsRatio=<value between 0 and 1>
```

Cette configuration permet de contrôler avec précision le nombre d'exécuteurs utilisateurs réservés par rapport à la capacité totale disponible.

Résolution des problèmes

Consultez les sections suivantes pour découvrir les solutions de dépannage.

Journalisation

AWS Glue utilise les profils de ressources Spark pour diviser l'exécution des tâches. AWS Glue utilise le profil utilisateur pour exécuter le code que vous avez fourni, tandis que le profil système

applique les politiques de Lake Formation. Vous pouvez accéder aux journaux des tâches exécutées en tant que profil utilisateur.

Interface utilisateur en direct et serveur d'historique Spark

L'interface utilisateur Live et le serveur d'historique Spark contiennent tous les événements Spark générés à partir du profil utilisateur et les événements expurgés générés à partir du pilote système.

Vous pouvez voir toutes les tâches des pilotes utilisateur et système dans l'onglet Exécuteurs. Toutefois, les liens du journal ne sont disponibles que pour le profil utilisateur. En outre, certaines informations sont supprimées de Live UI, telles que le nombre d'enregistrements de sortie.

Échec de la tâche en raison d'autorisations insuffisantes pour Lake Formation

Assurez-vous que votre rôle d'exécution des tâches dispose des autorisations nécessaires pour exécuter SELECT et DESCRIBE sur la table à laquelle vous accédez.

Échec de l'exécution de la tâche avec RDD

AWS Glue ne prend actuellement pas en charge les opérations de jeu de données distribué résilient (RDD) sur les tâches compatibles avec Lake Formation.

Impossible d'accéder aux fichiers de données dans Amazon S3

Assurez-vous d'avoir enregistré l'emplacement du lac de données dans Lake Formation.

Exception de validation de sécurité

AWS Glue a détecté une erreur de validation de sécurité. Contactez le AWS support pour obtenir de l'aide.

Partage du catalogue de données et des tableaux AWS Glue entre les comptes

Vous pouvez partager des bases de données et des tables entre comptes tout en continuant à utiliser Lake Formation. Pour plus d'informations, consultez les [sections Partage de données entre comptes dans Lake Formation](#) et [How do I share AWS Glue Data Catalog and Tables cross-account using ?](#).

Le tableau suivant décrit un résumé de la manière de choisir entre un contrôle d'accès détaillé (FGAC) et un accès complet aux tables (FTA) pour votre charge de travail.

Fonctionnalité	Contrôle précis des accès (FGAC)	Accès complet aux tables (FTA)
Niveau d'accès	Niveau colonne/ligne	Tableau complet
Cas d'utilisation	Requêtes et ETL avec autorisations limitées	ETL
Impact sur les performances	Nécessite des transitions system/user spatiales pour l'évaluation du contrôle d'accès, ce qui augmente la latence	Performances optimisées

Utilisation d'Amazon S3 Access Grants avec AWS Glue


Avec la version 5.0 de Glue, Amazon S3 Access Grants fournit une solution de contrôle d'accès évolutive que vous pouvez utiliser pour augmenter l'accès à vos données Amazon S3 depuis AWS Glue. Si vous disposez d'une configuration d'autorisations complexe ou importante pour vos données S3, vous pouvez utiliser les subventions d'accès S3 pour adapter les autorisations de données S3 aux utilisateurs et aux rôles.

Utilisez les subventions d'accès S3 pour augmenter l'accès aux données Amazon S3 au-delà des autorisations accordées par le rôle d'exécution ou des rôles IAM associés aux identités ayant accès à votre AWS Glue tâche. Pour plus d'informations, voir la rubrique [Gestion des accès avec S3 Access Grants](#) du Guide de l'utilisateur Amazon S3.

Comment AWS Glue fonctionne le S3 Access Grants

AWS Glue les versions 5.0 et supérieures fournissent une intégration native avec S3 Access Grants. Vous pouvez activer les subventions d'accès S3 sur AWS Glue et exécuter des tâches Spark. Lorsqu'une tâche Spark demande à accéder aux données S3, Amazon S3 fournit des informations d'identification temporaires limitées au compartiment, au préfixe ou à l'objet concerné.

Vous trouverez ci-dessous un aperçu général de la manière AWS Glue d'accéder aux données auxquelles S3 Access Grants gère l'accès.



1. Un utilisateur soumet une tâche AWS Glue Spark qui utilise des données stockées dans Amazon S3.
2. AWS Glue fait une demande de subventions d'accès S3 pour vendre des informations d'identification temporaires à l'utilisateur qui donnent accès au compartiment, au préfixe ou à l'objet.
3. AWS Glue renvoie des informations d'identification temporaires sous la forme d'un jeton STS (AWS Security Token Service) pour l'utilisateur. Le jeton permet uniquement d'accéder au compartiment, au préfixe ou à l'objet S3 concerné.
4. AWS Glue utilise le jeton STS pour récupérer les données de S3.
5. AWS Glue reçoit les données de S3 et renvoie les résultats à l'utilisateur.

Considérations relatives aux subventions d'accès S3 avec AWS Glue

Prenez note des comportements et des limites suivants lorsque vous utilisez S3 Access Grants avec AWS Glue.

Support des fonctionnalités

- S3 Access Grants est pris en charge avec AWS Glue les versions 5.0 et supérieures.
- Spark est le seul type de travail pris en charge lorsque vous utilisez S3 Access Grants avec AWS Glue.
- Delta Lake et Hudi sont les seuls formats de table ouverte pris en charge lorsque vous utilisez S3 Access Grants avec AWS Glue.
- Les fonctionnalités suivantes ne sont pas prises en charge pour une utilisation avec S3 Access Grants :

- Tables Apache Iceberg
- AWS Demandes CLI adressées à Amazon S3 qui utilisent des rôles IAM
- Accès S3 via le protocole open source S3A

Considérations comportementales

- AWS Glue fournit un cache d'informations d'identification pour garantir qu'un utilisateur n'a pas besoin de demander à plusieurs reprises les mêmes informations d'identification dans le cadre d'une tâche Spark. Par conséquent, demande AWS Glue toujours le privilège de niveau par défaut lorsqu'il demande des informations d'identification. Pour plus d'informations, voir la rubrique [Demande d'accès aux données S3](#) du Guide de l'utilisateur Amazon S3.

Configurez les autorisations d'accès S3 avec AWS Glue

Prérequis

L'appelant ou l'administrateur a créé une instance S3 Access Grants.

Configuration des AWS Glue politiques et de la configuration des tâches

Pour configurer S3 Access Grants avec, AWS Glue vous devez configurer des politiques de confiance et IAM, et transmettre la configuration via les paramètres de tâche.

1. Configurez les politiques de confiance minimale et IAM suivantes sur le rôle utilisé pour les subventions (le AWS Glue rôle qui exécute les sessions ou les tâches).

Stratégie d'approbation :

```
{
  "Sid": "Stmt1234567891011",
  "Action": [
    "sts:AssumeRole",
    "sts:SetSourceIdentity",
    "sts:SetContext"
  ],
  "Effect": "Allow",
  "Principal": {
    "Service": "access-grants.s3.amazonaws.com"
  },
  "Condition": {
```

```

        "StringEquals": {
            "aws:SourceAccount": "123456789012",
            "aws:SourceArn": "arn:aws:s3:<region>:123456789012:access-grants/
default"
        }
    }
}

```

Politique IAM :

```

{
    "Sid": "S3Grants",
    "Effect": "Allow",
    "Action": [
        "s3:GetDataAccess",
        "s3:GetAccessGrantsInstanceForPrefix"
    ],
    "Resource": "arn:aws:s3:<region>:123456789012:access-grants/default"
},
{
    "Sid": "BucketLevelReadPermissions",
    "Effect": "Allow",
    "Action": [
        "s3:ListBucket"
    ],
    "Resource": [
        "arn:aws:s3:::*"
    ],
    "Condition": {
        "StringEquals": {
            "aws:ResourceAccount": "123456789012"
        },
        "ArnEquals": {
            "s3:AccessGrantsInstanceArn": [
                "arn:aws:s3:<region>:123456789012:access-grants/default"
            ]
        }
    }
},
{
    "Sid": "ObjectLevelReadPermissions",
    "Effect": "Allow",
    "Action": [

```

```

        "s3:GetObject",
        "s3:GetObjectVersion",
        "s3:GetObjectAcl",
        "s3:GetObjectVersionAcl",
        "s3:ListMultipartUploadParts"
    ],
    "Resource": [
        "arn:aws:s3:::*"
    ],
    "Condition": {
        "StringEquals": {
            "aws:ResourceAccount": "123456789012"
        },
        "ArnEquals": {
            "s3:AccessGrantsInstanceArn": [
                "arn:aws:s3:<region>:123456789012:access-grants/default"
            ]
        }
    }
}

```

2. Dans votre AWS Glue tâche, transmettez la configuration Spark suivante via les paramètres de la AWS Glue tâche ou SparkConf.

```

--conf spark.hadoop.fs.s3.s3AccessGrants.enabled=true \
--conf spark.hadoop.fs.s3.s3AccessGrants.fallbackToIAM=false

```

Connexion et surveillance AWS Glue

Vous pouvez automatiser l'exécution de vos tâches ETL (extraction, transformation et chargement). AWS Glue fournit des indicateurs pour les robots d'exploration et les tâches que vous pouvez surveiller. Après avoir configuré le AWS Glue Data Catalog avec les métadonnées requises, AWS Glue fournit des statistiques sur la santé de votre environnement. Vous pouvez automatiser l'appel des crawlers et des tâches avec une planification temporelle basée sur cron. Vous pouvez également déclencher des tâches lorsqu'un déclencheur basé sur un événement s'exécute.

AWS Glue est intégré à AWS CloudTrail un service qui fournit un enregistrement des actions entreprises par un utilisateur, un rôle ou un AWS service dans AWS Glue. Si vous créez un suivi, vous pouvez activer la diffusion continue des CloudTrail événements vers un bucket Amazon Simple

Storage Service (Amazon S3), Amazon Logs et CloudWatch Amazon CloudWatch Events. Chaque événement ou entrée de journal contient des informations sur la personne ayant initié la demande.

Utilisez Amazon CloudWatch Events pour automatiser vos AWS services et répondre automatiquement aux événements du système tels que les problèmes de disponibilité des applications ou les modifications des ressources. Les événements issus AWS des services sont transmis à CloudWatch Events en temps quasi réel. Vous pouvez écrire des règles simples pour préciser les événements qui vous intéressent et les actions automatisées à effectuer quand un événement correspond à une règle.

 Consultez aussi

- [Automatiser AWS Glue avec EventBridge](#)
- [Journalisation entre comptes CloudTrail](#)

La journalisation constitue un aspect important de la sécurité dans le cloud. Vous devez configurer la journalisation de manière à ne pas capturer les secrets et le matériel confidentiel tout en capturant les informations nécessaires au débogage et à la sécurisation de votre infrastructure cloud. Assurez-vous de vous familiariser avec ce qui est enregistré.

Validation de conformité pour AWS Glue

Pour savoir si un [programme Services AWS de conformité Service AWS s'inscrit dans le champ d'application de programmes de conformité](#) spécifiques, consultez Services AWS la section de conformité et sélectionnez le programme de conformité qui vous intéresse. Pour des informations générales, voir Programmes de [AWS conformité Programmes AWS](#) de .

Vous pouvez télécharger des rapports d'audit tiers à l'aide de AWS Artifact. Pour plus d'informations, voir [Téléchargement de rapports dans AWS Artifact](#) .

Votre responsabilité en matière de conformité lors de l'utilisation Services AWS est déterminée par la sensibilité de vos données, les objectifs de conformité de votre entreprise et les lois et réglementations applicables. AWS fournit les ressources suivantes pour faciliter la mise en conformité :

- [Conformité et gouvernance de la sécurité](#) : ces guides de mise en œuvre de solutions traitent des considérations architecturales et fournissent les étapes à suivre afin de déployer des fonctionnalités de sécurité et de conformité.
- [Référence des services éligibles HIPAA](#) : liste les services éligibles HIPAA. Tous ne Services AWS sont pas éligibles à la loi HIPAA.
- AWS Ressources de <https://aws.amazon.com/compliance/resources/> de conformité — Cette collection de classeurs et de guides peut s'appliquer à votre secteur d'activité et à votre région.
- [AWS Guides de conformité destinés aux clients](#) — Comprenez le modèle de responsabilité partagée sous l'angle de la conformité. Les guides résument les meilleures pratiques en matière de sécurisation Services AWS et décrivent les directives relatives aux contrôles de sécurité dans de nombreux cadres (notamment le National Institute of Standards and Technology (NIST), le Payment Card Industry Security Standards Council (PCI) et l'Organisation internationale de normalisation (ISO)).
- [Évaluation des ressources à l'aide des règles](#) du guide du AWS Config développeur : le AWS Config service évalue dans quelle mesure les configurations de vos ressources sont conformes aux pratiques internes, aux directives du secteur et aux réglementations.
- [AWS Security Hub](#) — Cela Service AWS fournit une vue complète de votre état de sécurité interne AWS. Security Hub utilise des contrôles de sécurité pour évaluer vos ressources AWS et vérifier votre conformité par rapport aux normes et aux bonnes pratiques du secteur de la sécurité. Pour obtenir la liste des services et des contrôles pris en charge, consultez [Référence des contrôles Security Hub](#).
- [Amazon GuardDuty](#) — Cela Service AWS détecte les menaces potentielles qui pèsent sur vos charges de travail Comptes AWS, vos conteneurs et vos données en surveillant votre environnement pour détecter toute activité suspecte et malveillante. GuardDuty peut vous aider à répondre à diverses exigences de conformité, telles que la norme PCI DSS, en répondant aux exigences de détection des intrusions imposées par certains cadres de conformité.
- [AWS Audit Manager](#) — Cela vous Service AWS permet d'auditer en permanence votre AWS utilisation afin de simplifier la gestion des risques et la conformité aux réglementations et aux normes du secteur.

Résilience dans AWS Glue

L'infrastructure AWS mondiale est construite autour des AWS régions et des zones de disponibilité. AWS Les régions fournissent plusieurs zones de disponibilité physiquement séparées et isolées, connectées par un réseau à faible latence, à haut débit et hautement redondant. Avec les zones

de disponibilité, vous pouvez concevoir et exploiter des applications et des bases de données qui basculent automatiquement d'une zone de disponibilité à l'autre sans interruption. Les zones de disponibilité sont plus hautement disponibles, tolérantes aux pannes et évolutives que les infrastructures traditionnelles à un ou plusieurs centres de données.

Pour plus d'informations sur AWS les régions et les zones de disponibilité, consultez la section [Infrastructure AWS mondiale](#).

Pour plus d'informations sur la résilience des AWS Glue tâches, voir [Erreur : comportement de basculement entre VPCs entrées](#). AWS Glue

Sécurité de l'infrastructure dans AWS Glue

En tant que service géré, AWS Glue est protégé par les procédures de sécurité du réseau AWS mondial décrites dans le livre blanc [Amazon Web Services : présentation des processus de sécurité](#).

Vous utilisez des appels d'API AWS publiés pour accéder AWS Glue via le réseau. Les clients doivent supporter le protocole TLS (Sécurité de la couche transport) 1.0 ou une version ultérieure. Nous recommandons TLS 1.2 ou version ultérieure. Les clients doivent aussi prendre en charge les suites de chiffrement PFS (Perfect Forward Secrecy) comme Ephemeral Diffie-Hellman (DHE) ou Elliptic Curve Ephemeral Diffie-Hellman (ECDHE). La plupart des systèmes modernes tels que Java 7 et les versions ultérieures prennent en charge ces modes.

En outre, les demandes doivent être signées à l'aide d'un ID de clé d'accès et d'une clé d'accès secrète associée à un principal IAM. Vous pouvez également utiliser [AWS Security Token Service](#) (AWS STS) pour générer des informations d'identification de sécurité temporaires et signer les demandes.

Rubriques

- [Configuration des points de terminaison VPC de l'interface \(\) pour AWS PrivateLinkAWS Glue \(AWS PrivateLink\)](#)
- [Configuration d'Amazon partagé VPCs](#)

Configuration des points de terminaison VPC de l'interface () pour AWS PrivateLinkAWS Glue (AWS PrivateLink)

Vous pouvez établir une connexion privée entre votre VPC et AWS Glue en créant un point de terminaison VPC d'interface. Les points de terminaison de l'interface sont [AWS PrivateLink](#) alimentés

par une technologie qui vous permet d'accéder en privé AWS Glue APIs sans passerelle Internet, appareil NAT, connexion VPN ou connexion AWS Direct Connect. Les instances de votre VPC n'ont pas besoin d'adresses IP publiques pour communiquer avec AWS Glue APIs. Trafic entre votre VPC et AWS Glue ne quitte pas le réseau Amazon.

Chaque point de terminaison d'interface est représenté par une ou plusieurs [interfaces réseau Elastic](#) dans vos sous-réseaux.

Pour de plus amples informations, consultez [Points de terminaison VPC \(AWS PrivateLink\)](#) dans le Guide de l'utilisateur Amazon VPC.

Considérations relatives à AWS Glue Points de terminaison d'un VPC

Avant de configurer un point de terminaison VPC d'interface pour AWS Glue, assurez-vous de consulter les [propriétés et les limites des points de terminaison de l'interface](#) dans le guide de l'utilisateur Amazon VPC.

AWS Glue permet d'appeler toutes ses actions d'API depuis votre VPC.

Création d'un point de terminaison VPC d'interface pour AWS Glue

Vous pouvez créer un point de terminaison VPC pour AWS Glue service utilisant soit la console Amazon VPC, soit le AWS Command Line Interface (AWS CLI). Pour plus d'informations, consultez [Création d'un point de terminaison d'interface](#) dans le Guide de l'utilisateur Amazon VPC.

Créez un point de terminaison VPC pour AWS Glue en utilisant le nom de service suivant :

- `com.amazonaws. region.colle`

Si vous activez le DNS privé pour le point de terminaison, vous pouvez envoyer des demandes d'API à AWS Glue en utilisant son nom DNS par défaut pour la région, par exemple, `glue.us-east-1.amazonaws.com`.

Pour plus d'informations, consultez [Accès à un service via un point de terminaison d'interface](#) dans le Guide de l'utilisateur Amazon VPC.

Création d'une politique de point de terminaison VPC pour AWS Glue

Vous pouvez associer une politique de point de terminaison à votre point de terminaison VPC qui contrôle l'accès à AWS Glue. La politique précise les informations suivantes :

- Le principal qui peut exécuter des actions.
- Les actions qui peuvent être effectuées.
- Les ressources sur lesquelles les actions peuvent être exécutées.

Pour plus d'informations, consultez [Contrôle de l'accès aux services avec points de terminaison d'un VPC](#) dans le Guide de l'utilisateur Amazon VPC.

Exemple : politique de point de terminaison VPC pour AWS Glue pour permettre la création et la mise à jour d'emplois

Voici un exemple de politique de point de terminaison pour AWS Glue. Lorsqu'elle est attachée à un point de terminaison, cette politique accorde l'accès aux AWS Glue des actions pour tous les principaux sur toutes les ressources.

```
{
  "Statement": [
    {
      "Principal": "*",
      "Effect": "Allow",
      "Action": [
        "glue:CreateJob",
        "glue:UpdateJob",
        "iam:PassRole"
      ],
      "Resource": "*"
    }
  ]
}
```

Exemple : politique de point de terminaison d'un VPC autorisant l'accès au catalogue de données en lecture seule

Voici un exemple de politique de point de terminaison pour AWS Glue. Lorsqu'elle est attachée à un point de terminaison, cette politique accorde l'accès aux AWS Glue des actions pour tous les principaux sur toutes les ressources.

```
{
  "Statement": [
    {
      "Principal": "*",
```

```
    "Effect": "Allow",
    "Action": [
        "glue:GetDatabase",
        "glue:GetDatabases",
        "glue:GetTable",
        "glue:GetTables",
        "glue:GetTableVersion",
        "glue:GetTableVersions",
        "glue:GetPartition",
        "glue:GetPartitions",
        "glue:BatchGetPartition",
        "glue:SearchTables"
    ],
    "Resource": "*"
}
]
```

Configuration d'Amazon partagé VPCs

AWS Glue prend en charge les clouds privés virtuels partagés (VPCs) dans Amazon Virtual Private Cloud. Le partage Amazon VPC permet à plusieurs AWS comptes de créer leurs ressources applicatives, telles que des EC2 instances Amazon et des bases de données (Amazon Relational Database Service Amazon RDS), dans un Amazon partagé et géré de manière centralisée. VPCs Dans ce modèle, le compte propriétaire du VPC (propriétaire) partage un ou plusieurs sous-réseaux avec d'autres comptes (participants) appartenant à la même organisation. AWS Organizations Une fois un sous-réseau partagé, les participants peuvent afficher, créer, modifier et supprimer leurs ressources d'application contenues dans les sous-réseaux partagés avec eux.

Dans AWS Glue, pour créer une connexion avec un sous-réseau partagé, vous devez créer un groupe de sécurité au sein de votre compte et associer le groupe de sécurité au sous-réseau partagé.

Pour en savoir plus, consultez les rubriques suivantes :

- [Utilisation de Shared VPCs](#) dans le guide de l'utilisateur Amazon VPC
- [Qu'est-ce que c'est AWS Organizations ?](#) dans le guide de AWS Organizations l'utilisateur

Résolution des problèmes AWS Glue

Si vous rencontrez des problèmes lors de l' AWS Glue utilisation, consultez les rubriques de cette section.

Rubriques

- [Collecte d'informations AWS Glue de dépannage](#)
- [Résolution des erreurs Erreurs Spark](#)
- [Erreurs du robot d'exploration lorsque le robot utilise les autorisations de Lake Formation](#)
- [Résolution AWS Glue des erreurs Ray liées aux journaux](#)
- [AWS Glue exceptions relatives à l'apprentissage automatique](#)
- [AWS Glue quotas](#)

Collecte d'informations AWS Glue de dépannage

Si vous rencontrez des erreurs ou un comportement inattendu dans AWS Glue et que vous devez contacter AWS Support, vous devez d'abord recueillir des informations sur IDs les noms et les journaux associés à l'action échouée. La disponibilité de ces informations peut vous aider Support à résoudre les problèmes que vous rencontrez.

En plus de votre ID de compte, collectez les informations suivantes pour chacun de ces types de défaillances :

Lorsqu'un crawler échoue, collectez les informations suivantes :

- Nom du crawler

Les journaux des exécutions des robots d'exploration se trouvent dans CloudWatch Logs sous `/aws-glue/crawlers`.

Lorsqu'une connexion de test échoue, collectez les informations suivantes :

- Nom de la connexion
- ID de connexion
- La chaîne de connexion JDBC au format `jdbc:protocol://host:port/database-name`.

Les journaux des connexions de test se trouvent dans CloudWatch Logs sous `/aws-glue/testconnection`.

Lorsqu'une tâche échoue, collectez les informations suivantes :

- Nom de la tâche
- ID d'exécution de la tâche au format `j1_xxxxx`.

Les journaux des exécutions de tâches se trouvent dans CloudWatch Logs sous `/aws-glue/jobs`.

Résolution des erreurs Erreurs Spark

Si vous rencontrez des erreurs AWS Glue, utilisez les informations suivantes pour vous aider à trouver la source des problèmes et à les résoudre.

Note

Le AWS Glue GitHub référentiel contient des conseils de dépannage supplémentaires dans [AWS Glue les questions fréquemment posées](#).

Rubriques

- [Erreur : Ressource non disponible](#)
- [Erreur : Impossible de trouver le point de terminaison S3 ou la passerelle NAT du subnetId dans VPC](#)
- [Erreur : Règle de trafic entrant obligatoire dans le groupe de sécurité](#)
- [Erreur : Règle de trafic sortant obligatoire dans le groupe de sécurité](#)
- [Erreur : L'exécution du Job a échoué car le rôle transmis doit être autorisé à assumer le rôle pour le AWS Glue service](#)
- [Erreur : l' DescribeVpcEndpoints action n'est pas autorisée. impossible de valider l'ID VPC vpc-id](#)
- [Erreur : l' DescribeRouteTables action n'est pas autorisée. impossible de valider l'identifiant du sous-réseau : ID du sous-réseau dans l'identifiant du VPC : vpc-id](#)
- [Erreur : Impossible d'appeler ec2 : DescribeSubnets](#)
- [Erreur : Impossible d'appeler ec2 : DescribeSecurityGroups](#)
- [Erreur : Impossible de trouver le sous-réseau pour la zone de disponibilité](#)
- [Erreur : Exception d'exécution de tâche lors d'écriture sur une cible JDBC](#)
- [Erreur : Amazon S3 : l'opération n'est pas valide pour la classe de stockage de l'objet](#)

- [Erreur : Délai Amazon S3](#)
- [Erreur : Accès à Amazon S3 refusé](#)
- [Erreur : L'identifiant de la clé d'accès Amazon S3 n'existe pas](#)
- [Erreur : l'exécution d'une tâche échoue lors de l'accès à Amazon S3 avec un URI s3a://](#)
- [Erreur : Le jeton de service Amazon S3 a expiré](#)
- [Erreur : Aucun DNS privé trouvé pour l'interface réseau](#)
- [Erreur : Échec de l'allocation du point de terminaison de développement](#)
- [Erreur : Serveur de bloc-notes CREATE_FAILED](#)
- [Erreur : Échec du démarrage du bloc-notes local](#)
- [Erreur : Échec de l'exécution du crawler](#)
- [Erreur : les partitions n'ont pas été mises à jour](#)
- [Erreur : la mise à jour du signet de tâche a échoué en raison d'une incompatibilité de version](#)
- [Erreur : Une tâche retraite des données lorsque les signets de tâche sont activés](#)
- [Erreur : comportement de basculement entre VPCs AWS Glue](#)

Erreur : Ressource non disponible

En cas de AWS Glue renvoi d'un message indiquant que la ressource n'est pas disponible, vous pouvez consulter les messages d'erreur ou les journaux pour en savoir plus sur le problème. Les tâches suivantes décrivent des méthodes générales permettant de résoudre des problèmes.

- Pour tous les points de terminaison de connexion et de développement que vous utilisez, vérifiez que votre cluster n'est pas à court d'interfaces réseau Elastic.

Erreur : Impossible de trouver le point de terminaison S3 ou la passerelle NAT du subnetId dans VPC

Vérifiez l'ID du sous-réseau et l'ID du VPC dans le message afin de diagnostiquer le problème rencontré.

- Vérifiez que vous disposez d'un point de terminaison d'un VPC Amazon S3 configuré, ce qui est obligatoire avec AWS Glue. En outre, vérifiez votre passerelle NAT, si celle-ci fait partie de votre configuration. Pour de plus amples informations, veuillez consulter [Types de points de terminaison d'un VPC pour Amazon S3](#).

Erreur : Règle de trafic entrant obligatoire dans le groupe de sécurité

Au moins un groupe de sécurité doit ouvrir tous les ports d'entrée. Pour limiter le trafic, le groupe de sécurité source de votre règle de trafic entrant peut être limité au même groupe de sécurité.

- Pour toutes les connexions que vous utilisez, vérifiez que votre groupe de sécurité possède une règle de trafic entrant avec référence circulaire. Pour de plus amples informations, veuillez consulter [Configuration de l'accès réseau aux magasins de données](#).
- Lorsque vous utilisez un point de terminaison de développement, vérifiez que votre groupe de sécurité possède une règle de trafic entrant avec référence circulaire. Pour de plus amples informations, veuillez consulter [Configuration de l'accès réseau aux magasins de données](#).

Erreur : Règle de trafic sortant obligatoire dans le groupe de sécurité

Au moins un groupe de sécurité doit ouvrir tous les ports de sortie. Pour limiter le trafic, le groupe de sécurité source de votre règle de trafic sortant peut être limité au même groupe de sécurité.

- Pour toutes les connexions que vous utilisez, vérifiez que votre groupe de sécurité possède une règle de trafic sortant avec référence circulaire. Pour de plus amples informations, veuillez consulter [Configuration de l'accès réseau aux magasins de données](#).
- Lorsque vous utilisez un point de terminaison de développement, vérifiez que votre groupe de sécurité possède une règle de trafic sortant avec référence circulaire. Pour de plus amples informations, veuillez consulter [Configuration de l'accès réseau aux magasins de données](#).

Erreur : L'exécution du Job a échoué car le rôle transmis doit être autorisé à assumer le rôle pour le AWS Glue service

L'utilisateur qui définit une tâche doit avoir l'autorisation pour `iam:PassRole` pour AWS Glue.

- Lorsqu'un utilisateur crée une AWS Glue tâche, vérifiez que le rôle de l'utilisateur contient une politique contenant `iam:PassRole` pour AWS Glue. Pour de plus amples informations, veuillez consulter [Étape 3 : associer une politique aux utilisateurs ou aux groupes qui accèdent AWS Glue](#).

Erreur : l' `DescribeVpcEndpoints` action n'est pas autorisée. impossible de valider l'ID VPC `vpc-id`

- Vérifiez la politique transmise AWS Glue pour `ec2:DescribeVpcEndpoints` obtenir l'autorisation.

Erreur : l' `DescribeRouteTables` action n'est pas autorisée. impossible de valider l'identifiant du sous-réseau : ID du sous-réseau dans l'identifiant du VPC : `vpc-id`

- Vérifiez la politique transmise AWS Glue pour `ec2:DescribeRouteTables` obtenir l'autorisation.

Erreur : Impossible d'appeler `ec2:DescribeSubnets`

- Vérifiez la politique transmise AWS Glue pour `ec2:DescribeSubnets` obtenir l'autorisation.

Erreur : Impossible d'appeler `ec2:DescribeSecurityGroups`

- Vérifiez la politique transmise AWS Glue pour `ec2:DescribeSecurityGroups` obtenir l'autorisation.

Erreur : Impossible de trouver le sous-réseau pour la zone de disponibilité

- La zone de disponibilité n'est peut-être pas disponible pour AWS Glue. Créez et utilisez un sous-réseau dans une autre zone de disponibilité que celle indiquée dans le message.

Erreur : Exception d'exécution de tâche lors d'écriture sur une cible JDBC

Lorsque vous exécutez une tâche qui écrit sur une cible JDBC, la tâche peut rencontrer des erreurs dans les scénarios suivants :

- Si votre tâche écrit sur une table Microsoft SQL Server, que la table comporte des colonnes définies de type `Boolean`, alors que la table doit être prédéfinie dans la base de données SQL Server. Lorsque vous définissez la tâche sur la AWS Glue console à l'aide d'une cible SQL Server

avec l'option Créer des tables dans votre cible de données, ne mappez aucune colonne source à une colonne cible contenant un type de données `Boolean`. Vous pourriez rencontrer une erreur lors de l'exécution de la tâche.

Vous pouvez éviter cette erreur en procédant comme suit :

- Choisissez une table existante avec la colonne `Boolean` (Booléen).
- Modifiez la transformation `ApplyMapping` et mappez la colonne `Boolean` (Booléen) dans la source à un nombre ou à une chaîne de la cible.
- Modifiez la transformation `ApplyMapping` pour supprimer la colonne `Boolean` (Booléen) de la source.
- Si votre tâche écrit sur une table Oracle, vous devrez peut-être ajuster la longueur des noms des objets Oracle. Dans certaines versions d'Oracle, la longueur maximale d'un identifiant est limitée à 30 octets ou 128 octets. Cette limite affecte les noms de tables et les noms de colonnes des magasins de données cibles Oracle.

Vous pouvez éviter cette erreur en procédant comme suit :

- Nommez les tables cibles Oracle en respectant la limite de votre version.
- Les noms de colonnes par défaut sont générés à partir des noms de champs dans les données. Dans les situations où les noms des colonnes excèdent la limite, utilisez les transformations `ApplyMapping` ou `RenameField` pour modifier le nom de la colonne afin de respecter la limite.

Erreur : Amazon S3 : l'opération n'est pas valide pour la classe de stockage de l'objet

Si cette erreur est AWS Glue renvoyée, votre AWS Glue tâche a peut-être consisté à lire des données à partir de tables comportant des partitions entre les différents niveaux de classe de stockage Amazon S3.

- En utilisant des exclusions de classes de stockage, vous pouvez vous assurer que vos AWS Glue tâches fonctionneront sur des tables comportant des partitions entre ces niveaux de classe de stockage. Sans exclusion, les tâches qui lisent des données à partir de ces niveaux échouent avec l'erreur suivante : `AmazonS3Exception: The operation is not valid for the object's storage class.`

Pour de plus amples informations, veuillez consulter [Exclusion des classes de stockage Amazon S3](#).

Erreur : Délai Amazon S3

S'il AWS Glue renvoie une erreur d'expiration du délai de connexion, cela peut être dû au fait qu'il tente d'accéder à un compartiment Amazon S3 dans une autre AWS région.

- Un point de terminaison Amazon S3 VPC peut uniquement acheminer le trafic vers des compartiments au sein d'une région. AWS Si vous avez besoin de vous connecter à des compartiments dans d'autres régions, vous pouvez utiliser une passerelle NAT pour contourner ce problème. Pour plus d'informations, consultez [Passerelles NAT](#).

Erreur : Accès à Amazon S3 refusé

Si AWS Glue un message d'erreur de refus d'accès est renvoyé à un compartiment ou à un objet Amazon S3, cela peut être dû au fait que le rôle IAM fourni ne dispose pas d'une politique autorisant l'accès à votre magasin de données.

- Une tâche ETL doit avoir accès à un magasin de données Amazon S3 utilisé comme source ou cible. Un crawler doit avoir accès à un magasin de données Amazon S3 qu'il analyse. Pour de plus amples informations, veuillez consulter [Étape 2 : créer un rôle IAM pour AWS Glue](#).

Erreur : L'identifiant de la clé d'accès Amazon S3 n'existe pas

Si une erreur AWS Glue renvoie une clé d'accès ID n'existe pas lors de l'exécution d'une tâche, cela peut être dû à l'une des raisons suivantes :

- Une tâche ETL utilise un rôle IAM pour accéder aux banques de données, confirmez que le rôle IAM de votre tâche n'a pas été supprimé avant que la tâche commence.
- Un rôle IAM contient des autorisations permettant d'accéder à vos magasins de données, confirmez que la stratégie Amazon S3 attachée contenant `s3:ListBucket` est correcte.

Erreur : l'exécution d'une tâche échoue lors de l'accès à Amazon S3 avec un URI `s3a://`

Si une tâche renvoie une erreur similaire à Échec de l'analyse d'un document XML avec une classe de gestionnaire, la raison peut en être une défaillance lors de l'affichage de centaines de fichiers à l'aide d'un URI `s3a://`. Accédez plutôt à votre magasin de données à l'aide d'un URI `s3://`. Le suivi de l'exception suivant met en évidence les erreurs à rechercher :

```
1. com.amazonaws.SdkClientException: Failed to parse XML document with handler class
   com.amazonaws.services.s3.model.transform.XmlResponsesSaxParser$ListBucketHandler
2. at
   com.amazonaws.services.s3.model.transform.XmlResponsesSaxParser.parseXmlInputStream(XmlResponses
3. at
   com.amazonaws.services.s3.model.transform.XmlResponsesSaxParser.parseListBucketObjectsResponse
4. at com.amazonaws.services.s3.model.transform.Unmarshallers
   $ListObjectsUnmarshaller.unmarshall(Unmarshallers.java:70)
5. at com.amazonaws.services.s3.model.transform.Unmarshallers
   $ListObjectsUnmarshaller.unmarshall(Unmarshallers.java:59)
6. at
   com.amazonaws.services.s3.internal.S3XmlResponseHandler.handle(S3XmlResponseHandler.java:62)
7. at
   com.amazonaws.services.s3.internal.S3XmlResponseHandler.handle(S3XmlResponseHandler.java:31)
8. at
   com.amazonaws.http.response.AwsResponseHandlerAdapter.handle(AwsResponseHandlerAdapter.java:70)
9. at com.amazonaws.http.AmazonHttpClient
   $RequestExecutor.handleResponse(AmazonHttpClient.java:1554)
10. at com.amazonaws.http.AmazonHttpClient
   $RequestExecutor.executeOneRequest(AmazonHttpClient.java:1272)
11. at com.amazonaws.http.AmazonHttpClient
   $RequestExecutor.executeHelper(AmazonHttpClient.java:1056)
12. at com.amazonaws.http.AmazonHttpClient
   $RequestExecutor.doExecute(AmazonHttpClient.java:743)
13. at com.amazonaws.http.AmazonHttpClient
   $RequestExecutor.executeWithTimer(AmazonHttpClient.java:717)
14. at com.amazonaws.http.AmazonHttpClient
   $RequestExecutor.execute(AmazonHttpClient.java:699)
15. at com.amazonaws.http.AmazonHttpClient$RequestExecutor.access
   $500(AmazonHttpClient.java:667)
16. at com.amazonaws.http.AmazonHttpClient
   $RequestExecutionBuilderImpl.execute(AmazonHttpClient.java:649)
17. at com.amazonaws.http.AmazonHttpClient.execute(AmazonHttpClient.java:513)
```

```

18. at com.amazonaws.services.s3.AmazonS3Client.invoke(AmazonS3Client.java:4325)
19. at com.amazonaws.services.s3.AmazonS3Client.invoke(AmazonS3Client.java:4272)
20. at com.amazonaws.services.s3.AmazonS3Client.invoke(AmazonS3Client.java:4266)
21. at com.amazonaws.services.s3.AmazonS3Client.listObjects(AmazonS3Client.java:834)
22. at org.apache.hadoop.fs.s3a.S3AFileSystem.getFileStatus(S3AFileSystem.java:971)
23. at
    org.apache.hadoop.fs.s3a.S3AFileSystem.deleteUnnecessaryFakeDirectories(S3AFileSystem.java:115)
24. at org.apache.hadoop.fs.s3a.S3AFileSystem.finishedWrite(S3AFileSystem.java:1144)
25. at org.apache.hadoop.fs.s3a.S3AOutputStream.close(S3AOutputStream.java:142)
26. at org.apache.hadoop.fs.FSDataOutputStream
    $PositionCache.close(FSDataOutputStream.java:74)
27. at org.apache.hadoop.fs.FSDataOutputStream.close(FSDataOutputStream.java:108)
28. at org.apache.parquet.hadoop.ParquetFileWriter.end(ParquetFileWriter.java:467)
29. at
    org.apache.parquet.hadoop.InternalParquetRecordWriter.close(InternalParquetRecordWriter.java:1)
30. at
    org.apache.parquet.hadoop.ParquetRecordWriter.close(ParquetRecordWriter.java:112)
31. at
    org.apache.spark.sql.execution.datasources.parquet.ParquetOutputWriter.close(ParquetOutputWriter.java:1)
32. at org.apache.spark.sql.execution.datasources.FileFormatWriter
    $SingleDirectoryWriteTask.releaseResources(FileFormatWriter.scala:252)
33. at org.apache.spark.sql.execution.datasources.FileFormatWriter$$anonfun
    $org$apache$spark$sql$execution$databases$FileFormatWriter$$executeTask
    $3.apply(FileFormatWriter.scala:191)
34. at org.apache.spark.sql.execution.datasources.FileFormatWriter$$anonfun
    $org$apache$spark$sql$execution$databases$FileFormatWriter$$executeTask
    $3.apply(FileFormatWriter.scala:188)
35. at org.apache.spark.util.Utils
    $.tryWithSafeFinallyAndFailureCallbacks(Utils.scala:1341)
36. at org.apache.spark.sql.execution.datasources.FileFormatWriter$.org$apache$spark
    $sql$execution$databases$FileFormatWriter$$executeTask(FileFormatWriter.scala:193)
37. at org.apache.spark.sql.execution.datasources.FileFormatWriter$$anonfun$write$1$
    $anonfun$3.apply(FileFormatWriter.scala:129)
38. at org.apache.spark.sql.execution.datasources.FileFormatWriter$$anonfun$write$1$
    $anonfun$3.apply(FileFormatWriter.scala:128)
39. at org.apache.spark.scheduler.ResultTask.runTask(ResultTask.scala:87)
40. at org.apache.spark.scheduler.Task.run(Task.scala:99)
41. at org.apache.spark.executor.Executor$TaskRunner.run(Executor.scala:282)
42. at java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1149)
43. at java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:624)
44. at java.lang.Thread.run(Thread.java:748)

```

Erreur : Le jeton de service Amazon S3 a expiré

Lors du transfert de données vers et depuis Amazon Redshift, des informations d'identification Amazon S3 temporaires qui expirent au bout d'une heure sont utilisées. Si vous avez une tâche de longue durée, elle peut échouer. Pour plus d'informations sur la façon de configurer vos tâches de longue durée pour déplacer des données vers et à partir d'Amazon Redshift, veuillez consulter [aws-glue-programming-etl-connect-redshift-home](#).

Erreur : Aucun DNS privé trouvé pour l'interface réseau

Si une tâche échoue ou si l'allocation d'un point de terminaison échoue, cela peut être dû à un problème de configuration réseau.

- Si vous utilisez le DNS fourni par Amazon, la valeur de `enableDnsHostnames` doit être défini sur `true`. Pour plus d'informations, consultez [DNS](#).

Erreur : Échec de l'allocation du point de terminaison de développement

Si le provisionnement d'un point de terminaison de développement AWS Glue échoue, cela peut être dû à un problème de configuration réseau.

- Lorsque vous définissez un point de terminaison de développement, le VPC, le sous-réseau et les groupes de sécurité sont validés pour confirmer qu'ils répondent à certaines exigences.
- Si vous avez fourni la clé publique SSH facultative, vérifiez qu'il s'agit d'une clé publique SSH valide.
- Vérifiez dans la console VPC que votre VPC utilise DHCP option set (Jeu d'options DHCP) valide. Pour plus d'informations, consultez [Jeux d'options DHCP](#).
- Si le cluster reste dans l'état PROVISIONING (APPROVISIONNEMENT EN COURS), contactez AWS Support.

Erreur : Serveur de bloc-notes CREATE_FAILED

Si vous AWS Glue ne parvenez pas à créer le serveur bloc-notes pour un point de terminaison de développement, cela peut être dû à l'un des problèmes suivants :

- AWS Glue transmet un rôle IAM à Amazon EC2 lors de la configuration du serveur de blocs-notes. Le rôle IAM doit avoir une relation de confiance avec Amazon EC2.

- Le rôle IAM doit avoir un profil d'instance du même nom. Lorsque vous créez le rôle pour Amazon EC2 avec la console IAM, le profil d'instance portant le même nom est automatiquement créé. Recherchez un message d'erreur dans le journal concernant un nom de profil d'instance `iamInstanceProfile.name` non valide. Pour plus d'informations, consultez la section [Utilisation de profils d'instance](#).
- Vérifiez que votre rôle est autorisé à accéder aux compartiments `aws-glue*` dans la stratégie que vous transmettez pour créer le serveur de bloc-notes.

Erreur : Échec du démarrage du bloc-notes local

Si votre bloc-notes local ne démarre pas et renvoie des messages d'erreur indiquant qu'un répertoire ou dossier est introuvable, cela peut être dû à l'un des problèmes suivants :

- Si vous travaillez sous Microsoft Windows, assurez-vous que la variable d'environnement `JAVA_HOME` pointe vers le répertoire Java correct. Il est possible de mettre à jour Java sans mettre à jour cette variable, et si celle-ci pointe vers un dossier qui n'existe plus, les blocs-notes Jupyter échouent à démarrer.

Erreur : Échec de l'exécution du crawler

Si vous AWS Glue ne parvenez pas à exécuter un robot d'exploration pour cataloguer vos données, cela peut être dû à l'une des raisons suivantes. Commencez par vérifier si une erreur figure dans la liste des crawlers de la console AWS Glue . Vérifiez s'il y a une icône de point d'exclamation en regard du nom du crawler et passez la souris sur l'icône pour afficher les messages associés.

- Consultez les journaux du robot d'exploration exécuté dans CloudWatch Logs under `/aws-glue/crawlers`.

Erreur : les partitions n'ont pas été mises à jour

Si vos partitions n'ont pas été mises à jour dans le catalogue de données lorsque vous avez exécuté une tâche ETL, ces instructions de journal provenant de la `DataSink` classe figurant dans les CloudWatch journaux peuvent être utiles :

- « Attempting to fast-forward updates to the Catalog - namespace: » – Indique la base de données, la table et le catalogID que la tâche a tenté de modifier. Si cette instruction

n'est pas ici, vérifiez si `enableUpdateCatalog` a la valeur `true` et qu'elle est correctement passée en tant que paramètre `getSink()` ou dans `additional_options`.

- « `Schema change policy behavior:` » – Affiche la valeur du schéma `updateBehavior` que vous avez transmise.
- « `Schemas qualify (schema compare):` » – Sera vrai ou faux.
- « `Schemas qualify (case-insensitive compare):` » – Sera vrai ou faux.
- Si les deux valeurs sont fausses et `updateBehavior` que votre valeur n'est pas définie sur `UPDATE_IN_DATABASE`, votre `DynamicFrame` schéma doit être identique ou contenir un sous-ensemble des colonnes figurant dans le schéma de table du catalogue de données.

Pour en savoir plus sur la mise à jour des partitions, consultez [Mise à jour du schéma et ajout de nouvelles partitions dans le catalogue de données à l'aide de AWS Glue tâches ETL](#).

Erreur : la mise à jour du signet de tâche a échoué en raison d'une incompatibilité de version

Vous essayez peut-être de paramétrer les AWS Glue tâches pour appliquer la même transformation/logic on different datasets in Amazon S3. You want to track processed files on the locations provided. When you run the same job on the same source bucket and write to the same/different destination simultanément (simultanité >1). La tâche échoue avec cette erreur :

```
py4j.protocol.Py4JJavaError: An error occurred while
callingz:com.amazonaws.services.glue.util.Job.commit.:com.amazonaws.services.gluejobexecutor.m
Continuation update failed due to version mismatch. Expected version 2 but found
version 3
```

Solution : définissez la concurrence sur 1 ou n'exécutez pas la tâche simultanément.

Actuellement, AWS Glue les favoris ne prennent pas en charge les exécutions de tâches simultanées et les validations échoueront.

Erreur : Une tâche retraite des données lorsque les signets de tâche sont activés

Dans certains cas, vous avez activé les signets de AWS Glue tâches, mais votre tâche ETL retraite des données qui ont déjà été traitées lors d'une exécution précédente. Vérifiez si l'origine de l'erreur est l'une des causes suivantes :

Simultanéité max.

Le fait de définir un nombre maximal d'exécutions simultanées pour la tâche supérieur à la valeur par défaut de 1 peut interférer avec les signets des tâches. Cela peut se produire lorsque les signets des tâches vérifient l'heure de dernière modification des objets afin de déterminer quels objets doivent être retraités. Pour plus d'informations, consultez la discussion sur la simultanéité maximale dans [Configuration des propriétés des tâches pour les tâches Spark dans AWS Glue](#).

Objet de tâche manquant

Assurez-vous que votre script d'exécution de tâche se termine par les éléments suivants :

```
job.commit()
```

Lorsque vous incluez cet objet, AWS Glue enregistre l'horodatage et le chemin de la tâche exécutée. Si vous réexécutez la tâche avec le même chemin, seuls AWS Glue les nouveaux fichiers seront traités. Si vous n'incluez pas cet objet et si les signets de tâche sont activés, la tâche retraite les fichiers déjà traités en même temps que les nouveaux fichiers et crée une redondance dans le magasin de données cible de la tâche.

Paramètre de contexte de transformation manquant

Le contexte de transformation est un paramètre facultatif dans la classe `GlueContext`, mais les signets de tâche ne fonctionnent pas si vous ne l'incluez pas. Pour résoudre cette erreur, ajoutez le paramètre de contexte de transformation lorsque vous [créez le `DynamicFrame`](#), comme indiqué ci-dessous :

```
sample_dynF=create_dynamic_frame_from_catalog(database,
table_name,transformation_ctx="sample_dynF")
```

Source d'entrée

Si vous utilisez une base de données relationnelle (une connexion JDBC) pour la source d'entrée, les signets de travail fonctionnent uniquement si les clés primaires de la table sont classées par ordre séquentiel. Les signets de tâche fonctionnent pour les nouvelles lignes, mais pas pour les lignes mises à jour. En effet, les signets de tâche recherchent les clés primaires, qui existent déjà. Cela ne s'applique pas si la source des entrées est Amazon Simple Storage Service (Amazon S3).

Heure de la dernière modification

Pour les sources d'entrée Amazon S3, les signets de tâche vérifient l'heure de la dernière modification des objets, au lieu des noms de fichier, afin de contrôler quels objets doivent être retraités. Si les données de la source d'entrée ont été modifiées depuis votre dernière exécution de tâche, les fichiers sont traités de nouveau lorsque vous exécutez la tâche à nouveau.

Erreur : comportement de basculement entre VPCs AWS Glue

Le processus suivant est utilisé pour le basculement des tâches dans les versions AWS Glue 4.0 et antérieures.

Résumé : une AWS Glue connexion est sélectionnée au moment de l'envoi d'une tâche. Si l'exécution de la tâche rencontre des problèmes (manque d'adresses IP, connectivité à la source, problème de routage), l'exécution de la tâche échouera. Si de nouvelles tentatives sont configurées, je AWS Glue réessaierai avec la même connexion.

1. À chaque tentative d'exécution, AWS Glue vérifie l'état des connexions dans l'ordre indiqué dans la configuration de la tâche, jusqu'à ce qu'il en trouve une utilisable. En cas de défaillance d'une zone de disponibilité (AZ), les connexions en provenance de cette zone échoueront à la vérification et seront ignorées.
2. AWS Glue valide la connexion avec ce qui suit :
 - vérification de la validité de l'identifiant et du sous-réseau Amazon VPC ;
 - vérification de l'existence d'une passerelle NAT ou d'un point de terminaison Amazon VPC ;
 - vérification que le sous-réseau dispose de plus de zéro adresse IP allouée ;
 - vérification que la zone de disponibilité est saine.

AWS Glue Impossible de vérifier la connectivité au moment de la soumission de l'exécution de la tâche.

3. Pour les tâches utilisant Amazon VPC, tous les pilotes et exécuteurs seront créés dans la même zone de disponibilité avec la connexion sélectionnée au moment de la soumission de l'exécution de la tâche.
4. Si de nouvelles tentatives sont configurées, je AWS Glue réessaierai avec la même connexion. En effet, nous ne pouvons pas garantir que les problèmes liés à cette connexion dureront longtemps. Si une zone de disponibilité échoue, les exécutions de tâches existantes (en fonction de l'étape de l'exécution de la tâche) dans cette zone de disponibilité peuvent échouer. Une nouvelle tentative devrait détecter un échec de la zone de disponibilité et choisir une autre zone pour la nouvelle exécution.

Erreurs du robot d'exploration lorsque le robot utilise les autorisations de Lake Formation

Utilisez les informations ci-dessous pour diagnostiquer et résoudre divers problèmes lors de la configuration du Crawler à l'aide des informations d'identification de Lake Formation.

Erreur : l'emplacement S3 : s3://examplepath n'est pas enregistré

Pour qu'un Crawler puisse s'exécuter à l'aide des informations d'identification de Lake Formation, vous devez d'abord configurer les autorisations Lake Formation. Pour résoudre cette erreur, veuillez enregistrer l'emplacement Amazon S3 cible dans Lake Formation. Pour plus d'informations, consultez la rubrique [Enregistrement d'un emplacement Amazon S3](#).

Erreur : L'utilisateur/le rôle n'est pas autorisé à exécuter : lakeformation : on resource GetDataAccess

Veuillez ajouter la permission `lakeformation:GetDataAccess` au rôle crawler à l'aide de la console IAM ou AWS CLI. Avec cette autorisation, Lake Formation accède à la demande d'informations d'identification temporaires pour accéder aux données. Consultez la politique ci-dessous :

```
{
  "Version": "2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "lakeformation:GetDataAccess"
    ],
    "Resource": "*"
  }
}
```

Erreur : autorisation(s) insuffisante(s) sur Lake Formation (nom de la base de données : ExampleDatabase, nom de la table : ExampleTable)

Dans la console Lake Formation (<https://console.aws.amazon.com/lakeformation/>), accordez au rôle d'explorateur des autorisations d'accès (`Create`, `Describe`, `Alter`) sur la base de données, qui est spécifiée comme base de données de sortie. Vous pouvez également accorder des autorisations sur

le tableau. Pour plus d'informations, consultez la rubrique [Octroi d'autorisations de base de données via la méthode de ressource nommée](#).

Erreur : autorisation(s) insuffisante(s) pour Lake Formation sur s3://exemplepath

1. Indexation de site web intercompte

- a. Connectez-vous à la console Lake Formation (<https://console.aws.amazon.com/lakeformation/>) en utilisant le compte sur lequel le bucket Amazon S3 est enregistré (compte B). Accordez des autorisations d'emplacement des données au compte sur lequel le crawler sera exécuté. Cela permettra au crawler de lire les données depuis l'emplacement Amazon S3 cible.
- b. Dans le compte où le crawler est créé (compte A), accordez des autorisations emplacement des données sur l'emplacement Amazon S3 cible au rôle IAM utilisé pour l'exécution du crawler afin que le crawler puisse lire les données depuis la destination dans Lake Formation. Pour plus d'informations, consultez la rubrique [Octroi d'autorisations d'emplacement de données \(compte externe\)](#).

2. Indexation de site web dans le compte (le crawler et l'emplacement Amazon S3 enregistré sont dans le même compte) : accordez des autorisations d'emplacement de données au rôle IAM utilisé pour l'exécution du crawler à l'emplacement Amazon S3 pour que le crawler puisse lire les données de la cible dans Lake Formation. Pour plus d'informations, consultez la rubrique [Octroi d'autorisations d'emplacement de données \(même compte\)](#).

Questions fréquemment posées sur la configuration du crawler à l'aide des informations d'identification Lake Formation

1. Comment configurer un crawler pour qu'il fonctionne à l'aide des informations d'identification Lake Formation en utilisant la AWS Console ?

Dans la AWS Glue console (<https://console.aws.amazon.com/glue/>), lors de la configuration du robot d'exploration, sélectionnez l'option Utiliser les informations d'identification de Lake Formation pour analyser la source de données Amazon S3. Pour l'exploration entre comptes, spécifiez l'ID Compte AWS auquel l'emplacement Amazon S3 cible est enregistré auprès de Lake Formation. Le champ accountId est facultatif pour l'indexation de site web intégrée au compte.

2. Comment configurer un crawler pour qu'il fonctionne à l'aide des informations d'identification Lake Formation en utilisant AWS CLI ?

Lors de l'appel de l'API `CreateCrawler`, ajoutez `LakeFormationConfiguration` :

```
"LakeFormationConfiguration": {  
  "UseLakeFormationCredentials": true,  
  "AccountId": "111111111111" (AWS account ID where the target Amazon S3 location  
  is registered with Lake Formation)  
}
```

3. Quelles sont les cibles prises en charge pour Crawler à l'aide des informations d'identification Lake Formation ?

Un Crawler utilisant les informations d'identification Lake Formation n'est pris en charge que pour Amazon S3 (indexation de site web dans le compte et entre comptes) et pour les cibles de catalogue de données dans le compte (où l'emplacement sous-jacent est Amazon S3), et dans les cibles Apache Iceberg.

4. Puis-je crawler plusieurs compartiments Amazon S3 au sein crawler à l'aide des informations d'identification Lake Formation ?

Non. Pour les cibles d'indexation de site web utilisant le distributeur d'informations d'identification Lake Formation, les emplacements Amazon S3 sous-jacents doivent appartenir au même compartiment. Par exemple, les clients peuvent utiliser plusieurs sites cibles (`s3://bucket1/folder1`, `s3://bucket1/folder2`) s'ils se trouvent sous le même compartiment (`bucket1`). La spécification de différents compartiments (`s3://bucket1/folder1`, `s3://bucket2/folder2`) n'est pas prise en charge.

Résolution AWS Glue des erreurs Ray liées aux journaux

AWS Glue fournit un accès aux journaux émis par les processus Ray pendant l'exécution du job. En cas d'erreurs ou de comportements inattendus dans les tâches Ray, collectez d'abord des informations à partir des journaux pour déterminer la cause de l'échec. Nous fournissons également des journaux similaires pour les sessions interactives. Les journaux de sessions sont identifiables par le préfixe `/aws-glue/ray/sessions`.

Les lignes de journal sont envoyées CloudWatch en temps réel, au fur et à mesure de l'exécution de votre tâche. Les instructions d'impression sont ajoutées aux CloudWatch journaux une fois l'exécution terminée. Les journaux sont conservés pendant deux semaines après l'exécution d'une tâche.

Inspection des journaux de tâches Ray

Lorsqu'une tâche échoue, collectez le nom et l'ID d'exécution de celle-ci. Vous les trouverez dans la AWS Glue console. Accédez à la page de la tâche, puis à l'onglet Runs (Exécutions). Les journaux des tâches Ray sont stockés dans les groupes de CloudWatch journaux dédiés suivants.

- `/aws-glue/ray/jobs/script-log/` : stocke les journaux émis par votre script Ray principal.
- `/aws-glue/ray/jobs/ray-monitor-log/` : stocke les journaux émis par le processus de scalabilité automatique Ray. Ces journaux sont générés pour le nœud principal et non pour les autres composants master.
- `/aws-glue/ray/jobs/ray-gcs-logs/` : stocke les journaux émis par le processus GCS (global control store). Ces journaux sont générés pour le nœud principal et non pour les autres composants master.
- `/aws-glue/ray/jobs/ray-process-logs/` : stocke les journaux émis par d'autres processus Ray (principalement l'agent du tableau de bord) exécutés sur le nœud principal. Ces journaux sont générés pour le nœud principal et non pour les autres composants master.
- `/aws-glue/ray/jobs/ray-raylet-logs/` : stocke les journaux émis par chaque processus raylet. Ces journaux sont collectés dans un flux unique pour chaque composant master, y compris le nœud principal.
- `/aws-glue/ray/jobs/ray-worker-out-logs/` : stocke les journaux `stdout` pour chaque travail du cluster. Ces journaux sont générés pour chaque composant master, y compris le nœud principal.
- `/aws-glue/ray/jobs/ray-worker-err-logs/` : stocke les journaux `stderr` pour chaque travail du cluster. Ces journaux sont générés pour chaque composant master, y compris le nœud principal.
- `/aws-glue/ray/jobs/ray-runtime-env-log/` : stocke les journaux relatifs au processus de configuration Ray. Ces journaux sont générés pour chaque composant master, y compris le nœud principal.

Résolution des erreurs liées aux tâches Ray

Pour comprendre l'organisation des groupes de journaux Ray et identifier les groupes de journaux qui vous aideront à résoudre vos erreurs, vous devez disposer d'informations de base sur l'architecture Ray.

Dans l' AWS Glue ETL, un worker correspond à une instance. Lorsque vous configurez des travailleurs pour une AWS Glue tâche, vous définissez le type et le nombre d'instances dédiées à la tâche. Ray utilise le terme travail de différentes manières.

Ray utilise le nœud principal et le composant master pour distinguer les responsabilités d'une instance au sein d'un cluster Ray. Un composant master Ray peut héberger plusieurs processus acteurs qui effectuent des calculs afin d'obtenir le résultat de vos calculs distribués. Les acteurs qui exécutent une réplique d'une fonction sont appelés réplicas. Les réplicas d'acteurs peuvent également être appelés processus de travail. Les réplicas peuvent également s'exécuter sur le nœud principal, connu sous le nom de tête, car il exécute des processus supplémentaires pour coordonner le cluster.

Chaque acteur qui contribue à votre calcul génère son propre flux de journaux. Ce scénario nous donne quelques informations :

- Le nombre de processus qui émettent des journaux peut être supérieur au nombre de travaux qui sont alloués à la tâche. Souvent, chaque cœur de chaque instance comporte un acteur.
- Les nœuds principaux Ray émettent des journaux de gestion et de démarrage du cluster. En revanche, les composants master Ray émettent uniquement des journaux pour le travail qui les concerne.

Pour plus d'informations sur l'architecture Ray, consultez [Architecture Whitepapers](#) (Livres blancs sur l'architecture) dans la documentation Ray.

Problème : accès à Amazon S3

Vérifiez le message d'échec de la tâche exécutée. Si ce dernier ne fournit pas suffisamment d'informations, vérifiez `/aws-glue/ray/jobs/script-log/`.

Problème : gestion de la dépendance PIP

Vérifiez `/aws-glue/ray/jobs/ray-runtime-env-log/`.

Problème : inspection des valeurs intermédiaires dans le processus principal

Écrivez dans `stderr` ou `stdout` depuis votre script principal, et récupérez les journaux dans `/aws-glue/ray/jobs/script-log/`.

Problème : inspection des valeurs intermédiaires dans un processus enfant

Écrivez dans `stderr` ou `stdout` depuis votre fonction `remote`. Récupérez ensuite les journaux depuis `/aws-glue/ray/jobs/ray-worker-out-logs/` ou `/aws-glue/ray/jobs/ray-worker-err-logs/`. Votre fonction a pu être exécutée sur n'importe quel réplica. Vous pouvez donc être amené à examiner plusieurs journaux pour identifier la sortie souhaitée.

Problème : interprétation des adresses IP dans les messages d'erreur

Dans certaines situations d'erreur, votre tâche peut émettre un message d'erreur contenant une adresse IP. Ces adresses IP sont éphémères et sont utilisées par le cluster pour identifier les nœuds et communiquer entre eux. Les journaux d'un nœud seront publiés dans un flux de journaux avec un suffixe unique basé sur l'adresse IP.

Dans CloudWatch, vous pouvez filtrer vos journaux pour inspecter ceux spécifiques à cette adresse IP en identifiant ce suffixe. Par exemple, étant donné `FAILED_IP` et `JOB_RUN_ID`, vous pouvez identifier le suffixe avec :

```
filter @logStream like /JOB_RUN_ID/
| filter @message like /IP-/
| parse @message "IP-[*]" as ip
| filter ip like /FAILED_IP/
| fields replace(ip, ":", "_") as uIP
| stats count_distinct by uIP as logStreamSuffix
| display logStreamSuffix
```

AWS Glue exceptions relatives à l'apprentissage automatique

Cette rubrique décrit les codes d'erreur HTTP et les chaînes pour AWS Glue exceptions liées à l'apprentissage automatique. Les codes d'erreur et les chaînes d'erreur sont fournis pour chaque activité de machine learning susceptible de se produire lorsque vous effectuez une opération. Vous pouvez également déterminer s'il est possible de retenter l'opération qui a entraîné l'erreur.

Annuler MLTask RunActivity

Cette activité comporte les exceptions suivantes :

- `EntityNotFoundException` (400)

- « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »
- « Aucune exécution de tâche ML trouvée pour [taskRunId] : dans le compte [AccountID] pour transform [TransformName]. »

Nouvelle tentative possible : non.

Créez MLTask RunActivity

Cette activité comporte les exceptions suivantes :

- InvalidInputException (400)
 - Internal service failure due to unexpected input (Échec du service interne en raison d'une entrée inattendue)
 - « Un AWS Glue La source d'entrée de la table doit être spécifiée dans transform. »
 - Input source column [columnName] has an invalid data type defined in the catalog (Le type de données de la colonne de source d'entrée [Nom de la colonne] défini dans le catalogue n'est pas valide)
 - Exactly one input record table must be provided (Une seule table d'enregistrement en entrée doit être fournie)
 - Should specify database name (Doit spécifier le nom de la base de données)
 - Should specify table name (Doit spécifier le nom de la table)
 - Schema is not defined on the transform (Le schéma n'est pas défini sur la transformation)
 - Schema should contain given primary key: [primaryKey] (Le schéma doit contenir une clé primaire donnée : [Clé primaire])
 - Problem fetching the data catalog schema: [message] (Problème de récupération du schéma de catalogue de données : [message])
 - Cannot set Max Capacity and Worker Num/Type at the same time (Impossible de définir simultanément la capacité maximale et le num/type de travail)
 - « Les deux WorkerType et NumberOfWorkers doivent être réglés. »
 - « MaxCapacity devrait être >= [MaxCapacity]. »
 - « NumberOfWorkers devrait être >= [MaxCapacity]. »
 - Max retries should be non-negative (Les tentatives maximales ne peuvent pas être négatives)

- Find Matches parameters have not been set (Les paramètres de recherche de correspondances n'ont pas été définis)
- A primary key must be specified in Find Matches parameters (Une clé primaire doit être spécifiée dans les paramètres de recherche de correspondances)

Nouvelle tentative possible : non.

- AlreadyExistsException (400)
 - Transform with name [transformName] already exists (Une transformation appelée [Nom de la transformation] existe déjà)

Nouvelle tentative possible : non.

- IdempotentParameterMismatchException (400)
 - Idempotent create request for transform [transformName] had mismatching parameters (Les paramètres de la demande de création idempotente ne correspondent pas)

Nouvelle tentative possible : non.

- InternalServiceException (500)
 - Dependency failure (Échec de la dépendance)

Nouvelle tentative possible : oui.

- ResourceNumberLimitExceededException (400)
 - ML Transforms count ([count]) has exceeded the limit of [limit] transforms (Le nombre de transformations ML [nombre] a dépassé la limite de [nombre limite] transformations)

Nouvelle tentative possible : oui, une fois que vous aurez supprimé une transformation pour faire de la place à cette nouvelle transformation.

Supprimer MLTransform l'activité

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)
 - « Impossible de trouver MLTransform dans le compte [AccountID] avec le handle [TransformName] »

Nouvelle tentative possible : non.

Obtenez MLTask RunActivity

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)
 - « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »
 - « Aucune exécution de tâche ML trouvée pour [taskRunId] : dans le compte [AccountID] pour transform [TransformName]. »

Nouvelle tentative possible : non.

Obtenez MLTask RunsActivity

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)
 - « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »
 - « Aucune exécution de tâche ML trouvée pour [taskRunId] : dans le compte [AccountID] pour transform [TransformName]. »

Nouvelle tentative possible : non.

Obtenir de MLTransform l'activité

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)
 - « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »

Nouvelle tentative possible : non.

Obtenir de MLTransforms l'activité

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)
 - « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »

Nouvelle tentative possible : non.

- InvalidInputException (400)
 - Account ID can't be blank (L'ID de compte doit être renseigné)
 - Sorting not supported for column [column] (Le tri n'est pas pris en charge pour la colonne [colonne])
 - [column] can't be blank ([colonne] ne peut pas être vide)
 - Internal service failure due to unexpected input (Échec du service interne en raison d'une entrée inattendue)

Nouvelle tentative possible : non.

GetSaveLocationForTransformArtifactActivity

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)
 - « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »

Nouvelle tentative possible : non.

- InvalidInputException (400)
 - Unsupported artifact type [artifactType] (Type d'artefact [Type d'artefact] non pris en charge)
 - Internal service failure due to unexpected input (Échec du service interne en raison d'une entrée inattendue)

Nouvelle tentative possible : non.

GetTaskRunArtifactActivity

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)

- « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »
- « Aucune exécution de tâche ML trouvée pour [taskRunId] : dans le compte [AccountID] pour transform [TransformName]. »

Nouvelle tentative possible : non.

- InvalidInputException (400)
 - File name [fileName] is invalid for publish (Le nom de fichier [Nom de fichier] n'est pas valide pour la publication)
 - Cannot retrieve artifact for [taskType] task type (Impossible de récupérer l'artefact pour le type de tâche [Type de tâche])
 - Cannot retrieve artifact for [artifactType] (Impossible de récupérer l'artefact pour [Type d'artefact])
 - Internal service failure due to unexpected input (Échec du service interne en raison d'une entrée inattendue)

Nouvelle tentative possible : non.

Publier MLTransform ModelActivity

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)
 - « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »
 - An existing model with version - [version] cannot be found for account id - [accountId] - and transform id - [transformId] (Impossible de trouver un modèle existant avec la version [version] pour l'ID de compte [ID de compte] et l'ID de transformation [ID de transformation])

Nouvelle tentative possible : non.

- InvalidInputException (400)
 - File name [fileName] is invalid for publish (Le nom de fichier [Nom de fichier] n'est pas valide pour la publication)
 - Illegal leading minus sign on unsigned string [string] (Signe moins de début non valide sur une chaîne non signée [chaîne])
 - Bad digit at end of [string] (Chiffre incorrect à la fin de [chaîne])

- String value [string] exceeds range of unsigned long (La valeur de chaîne [chaîne] dépasse considérablement la plage des chaînes non signées)
- Internal service failure due to unexpected input (Échec du service interne en raison d'une entrée inattendue)

Nouvelle tentative possible : non.

PullLatestMLTransformModelActivity

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)
 - « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »

Nouvelle tentative possible : non.

- InvalidInputException (400)
 - Internal service failure due to unexpected input (Échec du service interne en raison d'une entrée inattendue)

Nouvelle tentative possible : non.

- ConcurrentModificationException (400)
 - Cannot create model version to train due to racing inserts with mismatching parameters (Impossible de créer une version de modèle pour l'entraînement en raison d'insertions de course avec des paramètres incorrects)
 - The ML Transform model for transform id [transformId] is stale or being updated by another process; Please retry (Le modèle de transformation ML pour l'ID [ID de transformation] est obsolète ou en cours de mise à jour par un autre processus. Veuillez réessayer)

Nouvelle tentative possible : oui.

PutJobMetadataForMLTransformActivité

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)

- « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »
- « Aucune exécution de tâche ML trouvée pour [taskRunId] : dans le compte [AccountID] pour transform [TransformName]. »

Nouvelle tentative possible : non.

- InvalidInputException (400)
 - Internal service failure due to unexpected input (Échec du service interne en raison d'une entrée inattendue)
 - Unknown job metadata type [jobType] (Type de métadonnées inconnu pour la tâche [Type de tâche])
 - Must provide a task run ID to update (Doit fournir un ID d'exécution de tâche à mettre à jour)

Nouvelle tentative possible : non.

StartExportLabelsTaskRunActivity

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)
 - « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »
 - No labelset exists for transformId [transformId] in account id [accountId] (Aucun jeu d'étiquettes n'existe pour l'ID de transformation [ID de transformations] dans l'ID de compte [ID de compte])

Nouvelle tentative possible : non.

- InvalidInputException (400)
 - [message]
 - S3 path provided is not in the same region as transform Expecting region - [region], but got - [region] (Le chemin S3 fourni n'est pas dans la même région que la transformation. La région attendue est [région], mais la région obtenue correspond à [région])

Nouvelle tentative possible : non.

StartImportLabelsTaskRunActivity

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)
 - « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »

Nouvelle tentative possible : non.

- InvalidInputException (400)
 - [message]
 - Invalid label file path (Chemin d'accès non valide au fichier d'étiquettes)
 - Cannot access the label file at [labelPath]. [message] (Impossible d'accéder au fichier d'étiquettes sous [Chemin]. [message])
 - Cannot use IAM role provided in the transform Role: [role] (Impossible d'utiliser le rôle IAM fourni dans la transformation. Rôle : [rôle])
 - Invalid label file of size 0 (Fichier d'étiquettes non valide avec la taille 0)
 - S3 path provided is not in the same region as transform Expecting region - [region], but got - [region] (Le chemin S3 fourni n'est pas dans la même région que la transformation. La région attendue est [région], mais la région obtenue correspond à [région])

Nouvelle tentative possible : non.

- ResourceNumberLimitExceededException (400)
 - Label file has exceeded the limit of [limit] MB (Le fichier d'étiquettes a dépassé la limite de [nombre] Mo)

Nouvelle tentative possible : non. Envisagez de fragmenter votre fichier d'étiquettes en plusieurs fichiers de petite taille.

Démarrer MLEvaluation TaskRunActivity

Cette activité comporte les exceptions suivantes :

- EntityNotFoundException (400)
 - « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »

Nouvelle tentative possible : non.

- `InvalidInputException` (400)
 - Exactly one input record table must be provided (Une seule table d'enregistrement en entrée doit être fournie)
 - Should specify database name (Doit spécifier le nom de la base de données)
 - Should specify table name (Doit spécifier le nom de la table)
 - Find Matches parameters have not been set (Les paramètres de recherche de correspondances n'ont pas été définis)
 - A primary key must be specified in Find Matches parameters (Une clé primaire doit être spécifiée dans les paramètres de recherche de correspondances)

Nouvelle tentative possible : non.

- `MLTransformNotReadyException` (400)
 - This operation can only be applied to a transform that is in a READY state (Cette opération ne peut être appliquée qu'à une transformation dont l'état est READY)

Nouvelle tentative possible : non.

- `InternalServiceException` (500)
 - Dependency failure (Échec de la dépendance)

Nouvelle tentative possible : oui.

- `ConcurrentRunsExceededException` (400)
 - ML Task Runs count [count] has exceeded the transform limit of [limit] task runs (Le nombre d'exécutions de tâches ML [nombre limite] a dépassé la limite de transformations de [nombre limite] exécutions de tâches)
 - ML Task Runs count [count] has exceeded the limit of [limit] task runs (Le nombre d'exécutions de tâches ML [nombre] a dépassé la limite de [nombre limite] exécutions de tâches)

Nouvelle tentative possible : oui, une fois l'exécution de la tâche terminée.

Démarrer MLLabeling SetGenerationTaskRunActivity

Cette activité comporte les exceptions suivantes :

- `EntityNotFoundException` (400)

- « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »

Nouvelle tentative possible : non.

- `InvalidInputException` (400)
 - Exactly one input record table must be provided (Une seule table d'enregistrement en entrée doit être fournie)
 - Should specify database name (Doit spécifier le nom de la base de données)
 - Should specify table name (Doit spécifier le nom de la table)
 - Find Matches parameters have not been set (Les paramètres de recherche de correspondances n'ont pas été définis)
 - A primary key must be specified in Find Matches parameters (Une clé primaire doit être spécifiée dans les paramètres de recherche de correspondances)

Nouvelle tentative possible : non.

- `InternalServiceException` (500)
 - Dependency failure (Échec de la dépendance)

Nouvelle tentative possible : oui.

- `ConcurrentRunsExceededException` (400)
 - ML Task Runs count [count] has exceeded the transform limit of [limit] task runs (Le nombre d'exécutions de tâches ML [nombre limite] a dépassé la limite de transformations de [nombre limite] exécutions de tâches)

Nouvelle tentative possible : oui, une fois les exécutions de tâches terminées.

MLTransformActivité de mise à jour

Cette activité comporte les exceptions suivantes :

- `EntityNotFoundException` (400)
 - « Impossible de trouver MLTransform dans le compte [AccountID] avec le descripteur [TransformName]. »

Nouvelle tentative possible : non.

- `InvalidInputException` (400)

- Another transform with name [transformName] already exists (Une autre transformation appelée [Nom de la transformation] existe déjà)
- [message]
- Transform name cannot be blank (Le nom de la transformation doit être renseigné)
- Cannot set Max Capacity and Worker Num/Type at the same time (Impossible de définir simultanément la capacité maximale et le num/type de travail)
- « Les deux WorkerType et NumberOfWorkers doivent être réglés. »
- « MaxCapacity devrait être $\geq$ [minMaxCapacity]. »
- « NumberOfWorkers devrait être $\geq$ [minNumWorkers]. »
- Max retries should be non-negative (Les tentatives maximales ne peuvent pas être négatives)
- Internal service failure due to unexpected input (Échec du service interne en raison d'une entrée inattendue)
- Find Matches parameters have not been set (Les paramètres de recherche de correspondances n'ont pas été définis)
- A primary key must be specified in Find Matches parameters (Une clé primaire doit être spécifiée dans les paramètres de recherche de correspondances)

Nouvelle tentative possible : non.

- AlreadyExistsException (400)
 - Transform with name [transformName] already exists (Une transformation appelée [Nom de la transformation] existe déjà)

Nouvelle tentative possible : non.

- IdempotentParameterMismatchException (400)
 - Idempotent create request for transform [transformName] had mismatching parameters (Les paramètres de la demande de création idempotente ne correspondent pas)

Nouvelle tentative possible : non.

AWS Glue quotas

Vous pouvez nous contacter AWS Support pour [demander une augmentation](#) des quotas de service répertoriés dans le Références générales AWS. Sauf indication contraire, chaque quota

est spécifique à la région. Pour plus d'informations, consultez [.AWS Glue Points de terminaison et quotas](#).

Améliorer les AWS Glue performances

Stratégie de base pour le réglage des performances

Afin d'améliorer les AWS Glue performances, vous pouvez envisager de mettre à jour certains AWS Glue paramètres liés aux performances. Lors de la préparation du réglage des paramètres, tenez compte des bonnes pratiques suivantes :

- Déterminez vos objectifs de performance avant de commencer à identifier les problèmes.
- Utilisez des métriques pour identifier les problèmes avant de tenter de modifier les paramètres de réglage.

Pour obtenir des résultats plus cohérents lors du réglage d'une tâche, élaborer une stratégie de base pour votre travail de réglage.

En général, le réglage des performances est effectué dans le flux de travail suivant :

1. Déterminez les objectifs de performance.
2. Mesurez les métriques.
3. Identifiez les goulots d'étranglement.
4. Réduisez l'impact des goulots d'étranglement.
5. Répétez les étapes 2 à 4 jusqu'à ce que vous atteigniez l'objectif prévu.

Adapter les stratégies à votre type de travail

Jobs Spark : suivez les instructions de la section [Meilleures pratiques pour le réglage AWS Glue des performances des tâches Apache Spark](#) sur AWS Prescriptive Guidance.

Autres tâches : vous pouvez optimiser AWS Glue les tâches shell Ray et AWS Glue Python en adaptant les stratégies disponibles dans d'autres environnements d'exécution.

Amélioration des performances AWS Glue pour les tâches Apache Spark

Afin d'améliorer les performances AWS Glue de Spark, vous pouvez envisager de mettre à jour certains paramètres liés aux performances AWS Glue et Spark.

Pour plus d'informations sur les stratégies spécifiques permettant d'identifier les goulots d'étranglement à l'aide de métriques et de réduire leur impact, consultez la section [Meilleures pratiques en matière de réglage AWS Glue des performances pour les tâches Apache Spark](#) sur AWS Prescriptive Guidance. Ce guide présente les principaux sujets applicables à Apache Spark dans tous les environnements d'exécution, tels que l'architecture Spark et les ensembles de données distribués résilients. À l'aide de ces rubriques, le guide vous explique comment mettre en œuvre des stratégies spécifiques d'optimisation des performances, telles que l'optimisation des shuffles et la parallélisation des tâches.

Vous pouvez identifier les goulots d'étranglement en configurant AWS Glue pour afficher l'interface utilisateur de Spark. Pour de plus amples informations, veuillez consulter [the section called “Surveillance à l'aide de l'interface utilisateur Spark”](#).

En outre, AWS Glue fournit des fonctionnalités de performance qui peuvent être applicables au type spécifique de magasin de données auquel votre tâche se connecte. Vous trouverez des informations de référence sur les paramètres de performance pour les magasins de données dans [the section called “Paramètres de connexion”](#).

Optimisation des lectures avec pushdown dans AWS Glue ETL

Le pushdown est une technique d'optimisation qui rapproche la logique de récupération des données de la source de vos données. La source peut être une base de données ou un système de fichiers tel qu'Amazon S3. Lorsque vous exécutez certaines opérations directement sur la source, vous pouvez économiser du temps et de la puissance de traitement en ne transférant pas toutes les données via le réseau vers le moteur Spark géré par AWS Glue.

Autrement dit, la poussée réduit l'analyse des données. Pour plus d'informations sur le processus permettant d'identifier le moment où cette technique est appropriée, consultez la section [Réduire la quantité de données analysées dans le guide](#) des meilleures pratiques pour le réglage des performances de AWS Glue pour les tâches Apache Spark sur le guide AWS prescriptif.

Pushdown de prédicat sur les fichiers stockés dans Amazon S3

Lorsque vous travaillez sur des fichiers organisés par préfixe sur Amazon S3, vous pouvez filtrer vos chemins Amazon S3 cibles en définissant un pushdown de prédicat. Plutôt que de lire le jeu de données complet et d'appliquer des filtres dans un `DynamicFrame`, vous pouvez appliquer directement le filtre aux métadonnées de partition stockées dans le catalogue de données AWS. Cette approche vous permet de lister et de lire de manière sélective uniquement les données

nécessaires. Pour plus d'informations sur ce processus, y compris l'écriture dans un compartiment par partitions, consultez [the section called “Gestion des partitions”](#).

Le pushdown de prédicats dans Amazon S3 s'effectue à l'aide du paramètre `push_down_predicate`. Prenons l'exemple d'un compartiment dans Amazon S3 que vous avez partitionné par année, mois et jour. Si vous souhaitez récupérer les données clients pour juin 2022, vous pouvez demander à AWS Glue de ne lire que les chemins Amazon S3 pertinents. Dans ce cas, le `push_down_predicate` est `year='2022' and month='06'`. En mettant tout cela ensemble, l'opération de lecture peut être réalisée comme suit :

Python

```
customer_records = glueContext.create_dynamic_frame.from_catalog(  
    database = "customer_db",  
    table_name = "customer_tbl",  
    push_down_predicate = "year='2022' and month='06'"  
)
```

Scala

```
val customer_records = glueContext.getCatalogSource(  
    database="customer_db",  
    tableName="customer_tbl",  
    pushDownPredicate="year='2022' and month='06'"  
).getDynamicFrame()
```

Dans le scénario précédent, `push_down_predicate` récupère une liste de toutes les partitions du catalogue de données AWS Glue et les filtre avant de lire les fichiers Amazon S3 sous-jacents. Bien que cela soit utile dans la plupart des cas, lorsque vous travaillez avec des jeux de données contenant des millions de partitions, le processus de liste des partitions peut prendre beaucoup de temps. Pour résoudre ce problème, le nettoyage des partitions côté serveur peut être utilisé pour améliorer les performances. Cela se fait en créant un index de partition pour vos données dans le catalogue de données AWS Glue. Pour plus d'informations sur les index de partition, consultez [the section called “Création d'index de partition”](#). Vous pouvez ensuite utiliser l'option `catalogPartitionPredicate` pour référencer l'index. Pour un exemple de récupération de partitions avec `catalogPartitionPredicate`, consultez [the section called “Prédicats de partition de catalogue”](#).

Pushdown lors de l'utilisation de sources JDBC

Le lecteur JDBC AWS Glue utilisé dans le pushdown prend en `GlueContext` charge les bases de données prises en charge en fournissant des requêtes SQL personnalisées qui peuvent être exécutées directement sur la source. Cela peut être réalisé en configurant le paramètre `sampleQuery`. Votre exemple de requête peut spécifier les colonnes à sélectionner et fournir un pushdown de prédicat pour limiter les données transférées vers le moteur Spark.

Par défaut, les exemples de requêtes fonctionnent sur un seul nœud, ce qui peut entraîner des échecs lors du traitement de volumes de données importants. Pour utiliser cette fonctionnalité afin d'interroger des données à grande échelle, vous devez configurer le partitionnement des requêtes en définissant `enablePartitioningForSampleQuery` sur `true`, ce qui distribue la requête à plusieurs nœuds via une clé de votre choix. Le partitionnement des requêtes nécessite également quelques autres paramètres de configuration. Pour plus d'informations sur le partitionnement des requêtes, consultez [the section called "Lecture en parallèle à partir de JDBC"](#).

Lors de la configuration `enablePartitioningForSampleQuery`, AWS Glue combinera votre prédicat pushdown avec un prédicat de partitionnement lors de l'interrogation de votre base de données. Vous `sampleQuery` devez terminer par un `AND for AWS Glue` pour ajouter des conditions de partitionnement. (Si vous ne fournissez pas de pushdown de prédicat, `sampleQuery` doit se terminer par un `WHERE`). Vous trouverez ci-dessous un exemple dans lequel nous poussons un prédicat vers le bas pour récupérer uniquement les lignes dont `id` est supérieur à 1 000. Cette `sampleQuery` ne renvoie que les colonnes de nom et d'emplacement pour les lignes où `id` est supérieur à la valeur spécifiée :

Python

```
sample_query = "select name, location from customer_tbl WHERE id>=1000 AND"
customer_records = glueContext.create_dynamic_frame.from_catalog(
    database="customer_db",
    table_name="customer_tbl",
    sample_query = "select name, location from customer_tbl WHERE id>=1000 AND",

    additional_options = {
        "hashpartitions": 36 ,
        "hashfield":"id",
        "enablePartitioningForSampleQuery":True,
        "sampleQuery":sample_query
    }
)
```

Scala

```
val additionalOptions = Map(
    "hashpartitions" -> "36",
    "hashfield" -> "id",
    "enablePartitioningForSampleQuery" -> "true",
    "sampleQuery" -> "select name, location from customer_tbl WHERE id >= 1000
AND"
)

val customer_records = glueContext.getCatalogSource(
    database="customer_db",
    tableName="customer_tbl").getDynamicFrame()
```

Note

Si `customer_tbl` votre catalogue de données et votre banque de données sous-jacente portent un nom différent, vous devez fournir le nom de la table sous-jacente dans `sample_query`, car la requête est transmise à la banque de données sous-jacente.

Vous pouvez également effectuer des requêtes sur des tables JDBC sans intégrer le AWS Glue Data Catalog. Au lieu de fournir un nom d'utilisateur et le mot de passe comme paramètres de la méthode, vous pouvez réutiliser les informations d'identification d'une connexion préexistante en fournissant `useConnectionProperties` et `connectionName`. Dans cet exemple, nous récupérons les informations d'identification à partir d'une connexion appelée `my_postgre_connection`.

Python

```
connection_options_dict = {
    "useConnectionProperties": True,
    "connectionName": "my_postgre_connection",
    "dbtable": "customer_tbl",
    "sampleQuery": "select name, location from customer_tbl WHERE id>=1000 AND",
    "enablePartitioningForSampleQuery": True,
    "hashfield": "id",
    "hashpartitions": 36
}
```



```
customer_records = glueContext.create_dynamic_frame.from_options(  
    connection_type="postgresql",  
    connection_options=connection_options_dict  
)
```

Scala

```
val connectionOptionsJson = """  
    {  
        "useConnectionProperties": true,  
        "connectionName": "my_postgre_connection",  
        "dbtable": "customer_tbl",  
        "sampleQuery": "select name, location from customer_tbl WHERE id>=1000 AND",  
        "enablePartitioningForSampleQuery" : true,  
        "hashfield" : "id",  
        "hashpartitions" : 36  
    }  
    """  
  
val connectionOptions = new JsonOptions(connectionOptionsJson)  
  
val dyf = glueContext.getSource("postgresql",  
    connectionOptions).getDynamicFrame()
```

Remarques et limites relatives au pushdown dans Glue AWS

Le Pushdown, en tant que concept, est applicable lors de la lecture à partir de sources autres que le streaming. AWS Glue prend en charge une variété de sources. La capacité à appuyer vers le bas dépend de la source et du connecteur.

- Lorsque vous vous connectez à Snowflake, vous pouvez utiliser l'option `query`. Des fonctionnalités similaires existent dans le connecteur Redshift de AWS Glue 4.0 et des versions ultérieures. Pour de plus amples informations sur la lecture à partir de Snowflake avec `query`, consultez [the section called “Lire dans Snowflake”](#).
- Le lecteur ETL DynamoDB ne prend pas en charge les filtres ou les prédicats pushdown. MongoDB et DocumentDB ne prennent pas non plus en charge ce type de fonctionnalité.
- Lors de la lecture de données stockées dans Amazon S3 dans des formats de table ouverts, la méthode de partitionnement des fichiers dans Amazon S3 n'est plus suffisante. Pour lire et écrire

à partir de partitions utilisant des formats de table ouverts, consultez la documentation relative au format.

- DynamicFrame les méthodes n'exécutent pas le pushdown de la projection Amazon S3. Toutes les colonnes seront lues à partir des fichiers qui satisfont au filtre du prédicat.
- Lorsque vous travaillez avec des `custom.jdbc` connecteurs dans AWS Glue, la possibilité d'appuyer vers le bas dépend de la source et du connecteur. Consultez la documentation du connecteur approprié pour vérifier si et comment il prend en charge le pushdown dans AWS Glue.

Utilisation de la mise à l'échelle automatique pour AWS Glue

Auto Scaling est disponible pour votre AWS Glue ETL, sessions interactives et tâches de streaming avec AWS Glue version 3.0 ou ultérieure.

Lorsque Auto Scaling est activé, vous bénéficiez des avantages suivants :

- AWS Glue ajoute et supprime automatiquement des travailleurs du cluster en fonction du parallélisme à chaque étape ou microlot de l'exécution du travail.
- Cela vous évite d'avoir à expérimenter et à décider du nombre de travailleurs à affecter à votre AWS Glue Emplois ETL.
- Avec le nombre maximum de travailleurs fixé, AWS Glue choisira les ressources de la bonne taille pour la charge de travail.
- Vous pouvez voir comment la taille du cluster change au cours de l'exécution de la tâche en consultant les CloudWatch métriques sur la page de détails de l'exécution de la tâche dans AWS Glue Studio.

Auto Scaling pour AWS Glue Les tâches ETL et de streaming permettent d'étendre et d'intégrer à la demande les ressources informatiques de votre AWS Glue emplois. L'augmentation d'échelle à la demande vous aide à allouer uniquement les ressources de calcul requises initialement au démarrage de l'exécution de la tâche, ainsi qu'à allouer les ressources requises en fonction de la demande pendant la tâche.

Auto Scaling prend également en charge la mise à l'échelle dynamique du AWS Glue ressources professionnelles au cours d'un travail. Au cours de l'exécution d'une tâche, lorsque plus d'exécuteurs sont demandés par votre application Spark, plus d'employés seront ajoutés au cluster. Lorsque l'exécuteur est inactif sans tâches de calcul actives, il sera supprimé de même que l'employé correspondant.

Les scénarios courants dans lesquels Auto Scaling contribue à réduire les coûts et l'utilisation de vos applications Spark incluent :

- un pilote Spark répertoriant un grand nombre de fichiers dans Amazon S3 ou effectuant un chargement alors que les exécuteurs sont inactifs
- Stages Spark exécutés avec seulement quelques exécuteurs en raison d'un provisionnement excessif
- des distorsions de données ou une demande de calcul inégale entre les étapes Spark

Prérequis

Auto Scaling n'est disponible que pour AWS Glue version 3.0 ou ultérieure. Pour utiliser Auto Scaling, vous pouvez suivre le [guide de migration](#) pour migrer vos jobs existants vers AWS Glue version 3.0 ou ultérieure ou créez de nouveaux emplois avec AWS Glue version 3.0 ou ultérieure.

Auto Scaling est disponible pour AWS Glue emplois avec le type de travailleur G.1X, G.2X, G.4X, G.8X, ou G.Ø25X (uniquement pour les tâches de streaming). DPU Les normes ne sont pas prises en charge.

Activer Auto Scaling dans AWS Glue Studio

Dans l'onglet Détails du Job dans AWS Glue Studio, choisissez le type Spark ou Spark Streaming, et la version Glue ultérieure **Glue 3.0** ou ultérieure. Ensuite, une case à cocher apparaîtra sous Type de travailleur.

- Sélectionnez l'option Automatically scale the number of workers (Mise à l'échelle automatique du nombre d'employés).
- Configurez le Nombre maximal d'employés pour définir le nombre maximal d'employés pouvant être transférés à l'exécution de la tâche.

Visual

Script

Job details

Runs

Data quality

Schedules

Version Control

Type

The type of ETL job. This is set automatically based on the types of data sources you have selected.

Spark

Glue version [Info](#)

Glue 4.0 - Supports spark 3.3, Scala 2, Python 3

Language

Python 3

Worker type

Set the type of predefined worker that is allowed when a job runs.

G 1X
(4vCPU and 16GB RAM)

☒ Automatically scale the number of workers

AWS Glue will optimize costs and resource usage by dynamically scaling the number of workers up and down throughout the job run. Requires Glue 3.0 or later.

Maximum number of workers

The number of workers you want AWS Glue to allocate to this job.

10

Activation de l'Auto Scaling avec la AWS CLI ou le SDK

Pour activer Auto Scaling à partir de la AWS CLI pour l'exécution de votre tâche, exécutez `start-job-run` la configuration suivante :

```
{
  "JobName": "<your job name>",
  "Arguments": {
    "--enable-auto-scaling": "true"
  },
  "WorkerType": "G.2X", // G.1X and G.2X are allowed for Auto Scaling Jobs
}
```

```
"NumberOfWorkers": 20, // represents Maximum number of workers
...other job run configurations...
}
```

Une fois l'exécution de la tâche ETL terminée, vous pouvez également appeler `get-job-run` pour vérifier l'utilisation réelle des ressources de la tâche exécutée en secondes DPU. Remarque : le nouveau champ `n'DPUSeconds` apparaîtra que pour vos tâches par lots dans la AWS Glue version 4.0 ou ultérieure activée avec Auto Scaling. Ce champ n'est pas pris en charge pour les tâches de streaming.

```
$ aws glue get-job-run --job-name your-job-name --run-id jr_xx --endpoint https://
glue.us-east-1.amazonaws.com --region us-east-1
{
  "JobRun": {
    ...
    "GlueVersion": "3.0",
    "DPUSeconds": 386.0
  }
}
```

Vous pouvez également configurer des exécutions de tâches avec Auto Scaling à l'aide du kit [SDK AWS Glue](#) en suivant la même configuration.

Activer Auto Scaling avec des sessions interactives

Pour activer Auto Scaling lors de la création de AWS Glue tâches avec des sessions interactives, consultez [la section Configuration des sessions AWS Glue interactives](#).

Conseils et considérations

Conseils et points à prendre en compte pour affiner AWS Glue Auto Scaling :

- Si vous n'avez aucune idée de la valeur initiale du nombre maximum de travailleurs, vous pouvez commencer par le calcul approximatif expliqué dans [Estimation du AWS Glue DPU](#). Vous ne devez pas configurer une valeur extrêmement élevée dans le nombre maximum de travailleurs pour de très faibles volumes de données.
- AWS Glue Auto Scaling configure `spark.sql.shuffle.partitions` et `spark.default.parallelism` se base sur le nombre maximum de DPU (calculé en fonction du nombre maximum de travailleurs et du type de travailleur) configurés sur la tâche. Si vous préférez

la valeur fixe pour ces configurations, vous pouvez remplacer ces paramètres par les paramètres de tâche suivants :

- Clé : `--conf`
- Value (Valeur) : `spark.sql.shuffle.partitions=200 --conf spark.default.parallelism=200`
- Pour les tâches de streaming, par défaut, la mise à l'échelle automatique AWS Glue ne s'effectue pas au sein de microlots et plusieurs microlots sont nécessaires pour lancer la mise à l'échelle automatique. Si vous souhaitez activer la mise à l'échelle automatique dans le cadre de microlots, veuillez fournir `--auto-scale-within-microbatch`. Pour plus d'informations, consultez la section [Référence des paramètres Job](#).

Surveillance d'Auto Scaling à l'aide CloudWatch des métriques Amazon

Les métriques de l' CloudWatch exécuteur sont disponibles pour votre AWS Glue jobs 3.0 ou version ultérieure si vous activez Auto Scaling. Les métriques peuvent être utilisées pour contrôler la demande et l'utilisation optimisée des exécuteurs dans leurs applications Spark activées avec Auto Scaling. Pour de plus amples informations, veuillez consulter [Surveillance AWS Glue en utilisant les CloudWatch métriques Amazon](#).


Vous pouvez également utiliser des indicateurs AWS Glue d'observabilité pour obtenir des informations sur l'utilisation des ressources. Par exemple, grâce à la `surveillanceglue.driver.workerUtilization`, vous pouvez contrôler la quantité de ressources réellement utilisée avec ou sans mise à l'échelle automatique. Autre exemple, en surveillant `glue.driver.skewness.job` et `glue.driver.skewness.stage`, vous pouvez voir à quel point les données sont faussées. Ces informations vous aideront à décider d'activer le dimensionnement automatique et d'affiner les configurations. Pour plus d'informations, consultez la section Surveillance avec [Surveillance avec AWS Glue Métriques d'observabilité](#).

- `colle.driver. ExecutorAllocationManager.exécuteurs. numberAllExecutors`
- `colle.driver. ExecutorAllocationManager.exécuteurs. numberMaxNeededExécuteurs`

Pour en savoir plus sur ces métriques, consultez [Surveillance de la planification des capacités de DPU](#).

Note

CloudWatch les métriques de l'exécuteur ne sont pas disponibles pour les sessions interactives.



Surveillance de l'Auto Scaling avec Amazon CloudWatch Logs

Si vous utilisez des sessions interactives, vous pouvez surveiller le nombre d'exécuteurs en activant Amazon CloudWatch Logs en continu et en recherchant le terme « exécuteur » dans les journaux, ou en utilisant l'interface utilisateur Spark. Pour ce faire, utilisez la `%%configure` magie pour activer la journalisation continue avec `enable auto scaling`.

```
%%configure{
  "--enable-continuous-cloudwatch-log": "true",
  "--enable-auto-scaling": "true"
}
```

Dans les CloudWatch événements Amazon Logs, recherchez « exécuteur » dans les journaux :

CloudWatch > Log groups > /aws-glue/sessions/error > 2c420420-29b3-42df-9efd-09c31c2f734e

Log events

You can use the filter bar below to search for and match terms, phrases, or values in your log events. [Learn more about filter patterns](#)

Q executor

Clear 1m 30m 1h 12h Custom UTC timezone Display


Timestamp	Message
2024-10-01T21:43:34.323Z	/usr/bin/java -cp /tmp:/opt/amazon/conf:/opt/amazon/glue-manifest.jar com.amazonaws.services.glue.PrepareLaunch --conf spark.dynamicAllocation.enabled=true --conf spark.shuffle.service.enabled=true --conf spark.dynamicAllocation.minExec...
2024-10-01T21:43:40.917Z	/usr/bin/java -cp /tmp:/opt/amazon/conf:/opt/amazon/glue-manifest.jar:/opt/aws_glue_connectors/selected/redshift/*:/opt/aws_glue_connectors/selected/datalake/*:/opt/aws_glue_connectors/selected/marketplace/*:/opt/aws_glue_connectors/se...
2024-10-01 21:43:55.686Z	2024-10-01 21:43:55.685 INFO [Thread-6] resource.ResourceProfile (Logging.scala:logInfo(61)): Default ResourceProfile created, executor resources: Map(cores -> name: cores, amount: 4, script: , vendor: , memory -> name: memory, amount: ...
2024-10-01 21:43:55.693Z	2024-10-01 21:43:55.693 INFO [Thread-6] resource.ResourceProfile (Logging.scala:logInfo(61)): Limiting resource is cpus at 4 tasks per executor
2024-10-01 21:43:56.852Z	2024-10-01 21:43:56.851 INFO [Thread-6] util.Utils (Logging.scala:logInfo(61)): Using initial executors = 1, max of spark.dynamicAllocation.initialExecutors, spark.dynamicAllocation.minExecutors and spark.executor.instances
2024-10-01 21:43:57.088Z	2024-10-01 21:43:57.088 INFO [allocator] glue.TaskGroupInterface (Logging.scala:logInfo(61)): creating executor task for executor 1; clientToken gr_c468f687-29e8-4371-847f-a8756843f945_e_1_a_spark-application-1727819036333
2024-10-01 21:43:57.170Z	2024-10-01 21:43:57.170 INFO [Thread-6] util.Utils (Logging.scala:logInfo(61)): Using initial executors = 1, max of spark.dynamicAllocation.initialExecutors, spark.dynamicAllocation.minExecutors and spark.executor.instances
2024-10-01 21:43:57.363Z	2024-10-01 21:43:57.363 INFO [allocator] glue.ExecutorTaskManagement (Logging.scala:logInfo(61)): executor task g-6028db5daec3f583e8511704ef855bdc7073c12 created for executor 1
2024-10-01 21:44:10.183Z	2024-10-01 21:44:10.045 INFO [dispatcher-CoarseGrainedScheduler] scheduler.JESSchedulerBackendJESAsSchedulerBackendEndpoint (Logging.scala:logInfo(61)): Registered executor NettyRpcEndpointRef(spark-client://Executor) (172.35.82.228:52...
2024-10-01 21:44:10.186Z	2024-10-01 21:44:10.185 INFO [spark-listener-group-shared] scheduler.ExecutorEventListener (Logging.scala:logInfo(61)): Got executor added event for 1 @ 1727819050204
2024-10-01 21:44:10.187Z	2024-10-01 21:44:10.186 INFO [spark-listener-group-shared] glue.ExecutorTaskManagement (Logging.scala:logInfo(61)): connected executor 1
2024-10-01 21:44:10.115Z	2024-10-01 21:44:10.114 INFO [spark-listener-group-executorManagement] dynamoLoc.ExecutorMonitor (Logging.scala:logInfo(61)): New executor 1 has registered (new total is 1)
2024-10-01 21:44:10.114	2024-10-01 21:44:10.114 INFO [spark-listener-group-executorManagement] dynamoLoc.ExecutorMonitor (Logging.scala:logInfo(61)): New executor 1 has registered (new total is 1)
2024-10-01 21:44:57.147Z	2024-10-01 21:44:57.147 INFO [status-poller] glue.ExecutorTaskManagement (Logging.scala:logInfo(61)): polling for executor task status
2024-10-01 21:45:57.198Z	2024-10-01 21:45:57.197 INFO [status-poller] glue.ExecutorTaskManagement (Logging.scala:logInfo(61)): polling for executor task status

Surveillance de Auto Scaling avec Spark UI

Lorsque Auto Scaling est activé, vous pouvez également surveiller les exécuteurs ajoutés et supprimés grâce à une mise à l'échelle et à une réduction dynamiques en fonction de la demande de votre AWS Glue tâches utilisant l'interface utilisateur de Glue Spark. Pour de plus amples informations, veuillez consulter [Activation de l'interface utilisateur Web d'Apache Spark pour AWS Glue jobs](#).

Lorsque vous utilisez des sessions interactives depuis Jupyter Notebook, vous pouvez exécuter la magie suivante pour activer le dimensionnement automatique avec l'interface utilisateur Spark :

```
%%configure{
  "--enable-auto-scaling": "true",
  "--enable-continuous-cloudwatch-log": "true"
}
```



Surveillance de l'utilisation du DPU d'exécution de la tâche Auto Scaling

Vous pouvez utiliser [AWS Glue Studio Job run view](#) pour vérifier l'utilisation du DPU de vos tâches Auto Scaling.

1. Choisissez Monitoring dans le volet AWS Glue Studio de navigation. La page Surveillance apparaît.
2. Faites défiler la page jusqu'à atteindre le graphique Exécutions de tâche.
3. Accédez à l'exécution de la tâche qui vous intéresse et faites défiler la page jusqu'à atteindre la colonne « heures » du DPU pour vérifier l'utilisation de l'exécution de la tâche spécifique.

Limites

AWS Glue streaming Auto Scaling ne prend actuellement pas en charge une DataFrame jointure de streaming avec une statique DataFrame créée en dehors de `ForEachBatch`. Une statique DataFrame créée à l'intérieur du `ForEachBatch` fonctionnera comme prévu.

Partitionnement de la charge de travail avec exécution limitée

Les erreurs dans les applications Spark proviennent généralement de scripts Spark inefficaces, d'exécution distribuée en mémoire de transformations à grande échelle et d'anomalies des jeux de données. Il existe de nombreuses raisons qui peuvent causer des problèmes de mémoire de pilote ou de l'exécuteur, par exemple une asymétrie de données, l'énumération d'un trop grand nombre d'objets ou de grands brassages de données. Ces problèmes apparaissent souvent lorsque vous traitez d'énormes quantités de données en attente avec Spark.

AWS Glue vous permet de résoudre les problèmes liés à l'OOM et de faciliter le traitement ETL grâce au partitionnement de la charge de travail. Lorsque le partitionnement de la charge de travail est activé, chaque exécution de travail ETL ne sélectionne que les données non traitées, avec une limite supérieure sur la taille du jeu de données ou le nombre de fichiers à traiter avec cette exécution de tâche. Les futures exécutions de tâches traiteront les données restantes. Par exemple, si 1 000 fichiers doivent être traités, vous pouvez définir le nombre de fichiers à 500 et les séparer en deux exécutions de tâche.

Le partitionnement de charge de travail est pris en charge uniquement pour les sources de données Amazon S3.

Activation du partitionnement de la charge de travail

Vous pouvez activer l'exécution limitée en définissant manuellement les options dans votre script ou en ajoutant des propriétés de table de catalogue.

Pour activer le partitionnement de la charge de travail avec une exécution limitée dans votre script :

1. Pour éviter le retraitement des données, activez les signets de tâche dans la nouvelle tâche ou celle existante. Pour plus d'informations, veuillez consulter la rubrique [Suivi des données traitées à l'aide des signets de tâches](#).
2. Modifiez votre script et définissez la limite dans les options supplémentaires du AWS Glue getSourceAPI. Vous devez également définir le contexte de transformation du signet de tâche pour stocker l'élément state. Par exemple :

Python

```
glueContext.create_dynamic_frame.from_catalog(  
    database = "database",  
    table_name = "table_name",  
    redshift_tmp_dir = "",  
    transformation_ctx = "datasource0",  
    additional_options = {  
        "boundedFiles" : "500", # need to be string  
        # "boundedSize" : "1000000000" unit is byte  
    }  
)
```

Scala

```
val datasource0 = glueContext.getCatalogSource(  
    database = "database", tableName = "table_name", redshiftTmpDir = "",  
    transformationContext = "datasource0",  
    additionalOptions = JsonOptions(  
        Map("boundedFiles" -> "500") // need to be string  
        // "boundedSize" -> "1000000000" unit is byte  
    )  
)  
.getDynamicFrame()
```

```
val connectionOptions = JsonOptions(  
    Map("paths" -> List(baseLocation), "boundedFiles" -> "30")
```

```
)  
val source = glueContext.getSource("s3", connectionOptions, "datasource0", "")
```

Pour activer le partitionnement de la charge de travail avec une exécution limitée dans votre table de catalogue de données :

1. Définissez les paires clé-valeur dans le champ `parameters` de votre structure de table dans le catalogue des données. Pour en savoir plus, veuillez consulter la rubrique [Affichage et modification des détails de table](#).
2. Définir la limite supérieure de la taille du jeu de données ou du nombre de fichiers traités :
 - Définir `boundedSize` à la taille cible du jeu de données, en octets. L'exécution de la tâche s'arrêtera après avoir atteint la taille cible de la table.
 - Définir `boundedFiles` au nombre cible de fichiers. L'exécution de la tâche s'arrêtera après le traitement du nombre cible de fichiers.

 Note

Vous ne devez définir que `boundedSize` ou `boundedFiles`, car une seule limite est prise en charge.

Configuration d'un AWS Glue déclencheur pour exécuter automatiquement la tâche

Une fois que vous avez activé l'exécution limitée, vous pouvez configurer un AWS Glue déclencheur pour exécuter automatiquement le travail et charger les données de manière incrémentielle lors d'exécutions séquentielles. Accédez au AWS Glue Console et créez un déclencheur, configurez l'heure de planification et associez-le à votre tâche. Ensuite, il déclenchera automatiquement l'exécution de la tâche suivante et traitera le nouveau lot de données.

Vous pouvez également utiliser AWS Glue des flux de travail pour orchestrer plusieurs tâches afin de traiter les données de différentes partitions en parallèle. Pour plus d'informations, consultez [AWS Glue Déclencheurs](#) et [AWS Glue Flux de travail](#).

Pour plus d'informations sur les cas d'utilisation et les options, consultez le blog [Optimisation des applications Spark avec le partitionnement de la charge de travail dans AWS Glue](#).

Problèmes connus pour AWS Glue

Notez les problèmes connus suivants pour AWS Glue.


Rubriques

- [Interdiction d'accès aux données inter-tâches](#)

Interdiction d'accès aux données inter-tâches

Pensez à la situation où vous en avez deux AWS Glue. Créez des tâches dans un seul AWS compte, chacune exécutée dans un compte distinct AWS Glue Cluster Spark. Les emplois utilisent AWS Glue connexions pour accéder aux ressources dans le même cloud privé virtuel (VPC). Dans ce cas, une tâche s'exécutant dans un cluster peut accéder aux données à partir de la tâche s'exécutant dans l'autre cluster.

Le schéma suivant illustre une telle situation.



Dans le schéma, AWS Glue Job-1 est en Cluster-1 cours d'exécution et Job-2 est en Cluster-2 cours d'exécution. Les deux tâches fonctionnent avec la même instance Amazon Redshift, qui réside dans le sous-réseau Subnet-1 d'un VPC. Subnet-1 peut être un sous-réseau public ou privé.

Job-1 transforme les données d'Amazon Simple Storage Service (Amazon Bucket-1 S3) et les écrit sur Amazon Redshift. Job-2 fait de même avec les données entrées Bucket-2. Job-1 utilise le rôle AWS Identity and Access Management (IAM) Role-1 (non illustré), qui donne accès à Bucket-1. Job-2 utilise Role-2 (non illustré), qui donne accès à Bucket-2.

Ces tâches comportent des chemins réseau qui leur permettent de communiquer avec les clusters des autres tâches et donc d'accéder aux données de ces dernières. Par exemple, Job-2 peut accéder aux données dans Bucket-1. Dans le schéma, le chemin en rouge illustre cet accès.

Pour éviter cette situation, nous vous recommandons d'attacher des configurations de sécurité différentes à Job-1 et Job-2. En attachant les configurations de sécurité, l'accès inter-tâches aux données est bloqué grâce à des certificats qui AWS Glue crée. Les configurations de sécurité peuvent être des configurations factices. En d'autres termes, vous pouvez créer les configurations de sécurité sans activer le chiffrement des données Amazon S3, des CloudWatch données Amazon ou des signets de tâches. Les trois options de chiffrement peuvent être désactivées.

Pour de plus amples informations sur les configurations de sécurité, veuillez consulter [the section called “Chiffrement des données écrites par AWS Glue”](#).

Pour attacher une configuration de sécurité à une tâche

1. Ouvrez la AWS Glue console à l'adresse <https://console.aws.amazon.com/glue/>.
2. Sur la page Configure the job properties (Configurer les propriétés de la tâche) de la tâche, développez la section Paramètres de configuration de sécurité, des bibliothèques de scripts et des tâches.
3. Sélectionnez une configuration de sécurité dans la liste.

Historique de la documentation pour AWS Glue

Modification	Description	Date
Support pour 14 nouveaux connecteurs natifs SaaS supplémentaires pour AWS Glue	Quatorze connecteurs natifs SaaS supplémentaires ont été ajoutés AWS Glue. Pour plus d'informations, consultez la section Ajout d'une AWS Glue connexion .	30 janvier 2025
Support pour 16 nouveaux connecteurs natifs SaaS supplémentaires pour AWS Glue	Seize connecteurs natifs SaaS supplémentaires ont été ajoutés AWS Glue. Pour plus d'informations, consultez la section Ajout d'une AWS Glue connexion .	17 décembre 2024
Génération automatique de statistiques sur les colonnes	AWS Glue Data Quality prend désormais en charge Amazon SageMaker AI LakeHouse les tables et les tables Iceberg, Delta et HUDI AWS Lake Formation gérées dans Data Catalog et ETL. Pour plus d'informations, consultez la section QualitéAWS Glue des données .	6 décembre 2024
Support pour les intégrations sans ETL	Zero-ETL est un ensemble d'intégrations entièrement gérées AWS qui minimise le besoin de créer des pipelines de données ETL. Pour plus d'informations, consultez la section Intégrations Zero-ETL .	3 décembre 2024

[Support pour les connexions réutilisables](#)

Un nouveau schéma de AWS Glue connexions fournit un moyen unifié de gérer les connexions de données entre les AWS services et les applications AWS Glue, tels qu'Amazon Athena et Amazon SageMaker Unified Studio. Pour plus d'informations, consultez la section [Connexion aux données](#).

3 décembre 2024

[Support pour AWS Glue la version 5.0.](#)

Ajout d'informations sur le support de AWS Glue la version 5.0. Les fonctionnalités incluent une mise à jour d'Apache Spark vers la version 3.52, une mise à jour de Java vers la version 17, des mises à jour du format de table ouvert, un contrôle d'accès précis natif de Spark, l'intégration de Sagemaker Lakehouse et de l'abstraction de l'entrepôt de données, le support dans Sagemaker Unified Studio, etc. Pour plus d'informations, consultez les [notes AWS Glue de publication](#) et [la migration des AWS Glue tâches vers la AWS Glue version 5.0](#).

3 décembre 2024

[Connexion à l' AWS Glue Data Catalog aide du point de AWS Glue terminaison Iceberg REST](#)

AWS Glue le point de terminaison Iceberg REST prend en charge les opérations d'API spécifiées dans la spécification REST d'Apache Iceberg. À l'aide d'un client REST Iceberg, vous pouvez connecter votre application exécutée sur un moteur d'analyse au catalogue REST hébergé dans le catalogue de données. Pour plus d'informations, consultez la section [Accès au catalogue de données](#).

3 décembre 2024

[Génération automatique de statistiques sur les colonnes](#)

Générez automatiquement des statistiques de colonne pour les nouvelles tables du AWS Glue Data Catalog. Pour plus d'informations, consultez la section [Génération automatique de statistiques de colonnes](#).

3 décembre 2024

[Support pour les mises à niveau de l'IA générative pour Apache Spark dans AWS Glue](#)

Spark Upgrades in AWS Glue permet aux ingénieurs de données et aux développeurs de mettre à niveau et de migrer, de mettre à niveau et de migrer leurs tâches AWS Glue Spark existantes vers les dernières versions de Spark à l'aide de l'IA générative. Pour plus d'informations, consultez la section [Analyse des mises à niveau avec l'IA](#).

22 novembre 2024

[Support pour la résolution des problèmes liés à l'IA générative pour Apache Spark dans AWS Glue](#)

La résolution des problèmes liés à l'IA générative pour les tâches Apache Spark AWS Glue permet aux ingénieurs de données et aux scientifiques de diagnostiquer et de résoudre facilement les problèmes liés à leurs applications Spark. Pour plus d'informations, consultez la section [Résolution des problèmes liés aux tâches Spark avec l'IA.](#)

22 novembre 2024

[Support pour les optimiseurs Iceberg pour accéder aux compartiments Amazon S3 dans un VPC](#)

AWS Glue Data Catalog prend en charge les optimiseurs de table Iceberg pour accéder aux compartiments Amazon S3 depuis un Virtual Private Cloud (AWS Glue VPC) spécifique via une connexion réseau. Pour plus d'informations, consultez [Optimisation des tables Iceberg.](#)

20 novembre 2024

[Support pour neuf nouveaux connecteurs natifs SaaS supplémentaires pour AWS Glue](#)

Neuf autres connecteurs natifs SaaS ont été ajoutés AWS Glue. Pour plus d'informations, consultez la section [Ajout d'une AWS Glue connexion.](#)

19 novembre 2024

[Support de dix nouveaux connecteurs natifs SaaS pour AWS Glue](#)

Dix connecteurs natifs SaaS ont été ajoutés AWS Glue. Pour plus d'informations, consultez la section [Ajout d'une AWS Glue connexion.](#)

15 novembre 2024

[Support pour la mise en file d'attente pour AWS Glue les tâches ETL](#)

Vous pouvez activer la mise en file d'attente pour exécuter des tâches ultérieurement, lorsqu'elles ne peuvent pas être exécutées immédiatement en raison de quotas de service. Pour plus d'informations, consultez [la section Configuration des propriétés des tâches Spark dans AWS Glue](#).

3 septembre 2024

[Changements de politique mis à jour](#)

Modifications documentées des `AwsGlueSessionUserRestrictedNotebookServiceRole` politiques `AwsGlueSessionUserRestrictedNotebookPolicy`et, nécessaires à la prise en charge tag-on-create des sessions avec clé de balise propriétaire. Pour plus d'informations, voir les [AWS Glue mises à jour des politiques AWS gérées](#).

30 août 2024

[La détection des anomalies et les règles dynamiques sont désormais disponibles pour tous](#)

AWS Glue Data Quality utilise un algorithme d'apprentissage automatique pour tirer des leçons des tendances passées, puis prévoir les valeurs futures afin de détecter les anomalies. Les règles dynamiques vous permettent de fournir des seuils dynamiques. Pour plus d'informations, consultez [Optimisation des performances des requêtes pour les tables Iceberg](#).

7 août 2024

[Changements de politique mis à jour](#)

Modifications documentées des `AwsGlueSessionUser` `RestrictedServiceRole` politiques `AwsGlueSessionUser` `RestrictedPolicy`et, nécessaires à la prise en charge `tag-on-create` des sessions avec clé de balise propriétaire. Pour plus d'informations, voir les [AWS Glue mises à jour des politiques AWS gérées](#).

5 août 2024

[La génération de statistiques de colonnes pour les tables Iceberg est désormais généralement disponible](#)

AWS Glue prend en charge le calcul et la mise à jour du nombre de valeurs distinctes (NDVs) pour chaque colonne des tables Iceberg. Pour plus d'informations, consultez la section [Détection des anomalies dans la section Qualité AWS Glue des données](#) et [Règles dynamiques](#).

9 juillet 2024

[Support pour les profils AWS Glue d'utilisation](#)

Les administrateurs peuvent créer des profils AWS Glue d'utilisation pour différentes catégories d'utilisateurs au sein du compte, telles que les développeurs, les testeurs et les équipes produit. Cette flexibilité permet aux administrateurs d'appliquer différents contrôles d'utilisation et de coûts pour chaque catégorie d'utilisateurs. Pour plus d'informations, consultez la section [Configuration des profils AWS Glue d'utilisation](#).

18 juin 2024

[Support pour un connecteur Salesforce AWS Glue pour Spark](#)

Ajout d'informations sur un nouveau AWS Glue connecteur pour Salesforce. Cette fonctionnalité vous permet d'utiliser Spark AWS Glue pour lire et écrire dans Salesforce dans les versions AWS Glue 4.0 et ultérieures. Pour plus d'informations, consultez [Connexion à Salesforce](#).

22 mai 2024

[Intégration des données Amazon Q dans AWS Glue \(GA\)](#)

L'intégration de données dans Amazon Q AWS Glue est une nouvelle fonctionnalité d'IA générative AWS Glue qui permet aux ingénieurs de données et aux développeurs ETL de créer des tâches d'intégration de données en langage naturel. Les ingénieurs et les développeurs peuvent demander à Q de créer des tâches, de résoudre des problèmes et de répondre à des questions concernant AWS Glue l'intégration des données. [Pour plus d'informations, consultez la rubrique Intégration des données Amazon Q dans AWS Glue](#). Cette fonctionnalité inclut une mise à jour des politiques `AwsGlueSessionUserRestrictionsPolicy`, `AwsGlueSessionUserRestrictionsNotebookServiceRole`, et `AwsGlueSessionUserRestrictionsServiceRole` AWS gérées. Pour plus d'informations, voir les [AWS Glue mises à jour des politiques AWS gérées](#).

30 avril 2024

[Intégration des données
Amazon Q dans AWS Glue
\(version préliminaire\)](#)

L'intégration de données dans Amazon Q AWS Glue est une nouvelle fonctionnalité d'IA générative AWS Glue qui permet aux ingénieurs de données et aux développeurs ETL de créer des tâches d'intégration de données en langage naturel. Les ingénieurs et les développeurs peuvent demander à Q de créer des tâches, de résoudre des problèmes et de répondre à des questions concernant AWS Glue l'intégration des données. [Pour plus d'informations, consultez la rubrique Intégration des données Amazon Q dans AWS Glue.](#) Cette fonctionnalité inclut une mise à jour de la politique `AwsGlueSessionUserRestrictedNotebookPolicy` AWS gérée. Pour plus d'informations, voir les [AWS Glue mises à jour des politiques AWS gérées.](#)

30 janvier 2024

[Mise à jour de la documentation pour le AWS Glue streaming](#)

Ajout d'un nouveau chapitre avec du contenu nouveau et réorganisé pour le AWS Glue streaming. Ce contenu décrit le fonctionnement du streaming AWS Glue, les caractéristiques du traitement des données en temps réel et la manière de surveiller vos tâches de streaming. Pour plus d'informations, veuillez consulter [AWS Glue Streaming](#).

27 décembre 2023

[Prise en charge de la détection détaillée des données sensibles](#)

La transformation Détecter les données sensibles permet de détecter, masquer ou supprimer des entités que vous définissez ou sont prédéfinies par AWS Glue. Les actions détaillées vous permettent en outre d'appliquer une action spécifique par entité. Pour plus d'informations, consultez la rubrique [Utilisation d'une détection détaillée des données sensibles](#).

26 novembre 2023

[Support pour le suivi des tâches à l'aide de métriques AWS Glue d'observabilité](#)

Utilisez les métriques AWS Glue d'observabilité pour obtenir des informations sur ce qui se passe dans vos tâches AWS Glue pour Apache Spark afin d'améliorer le triage et l'analyse des problèmes. Pour plus d'informations, consultez la section [Surveillance à l'aide de métriques AWS Glue d'observabilité](#).

26 novembre 2023

[Support pour la détection des anomalies dans le domaine de la qualité AWS Glue des données](#)

AWS Glue La détection des anomalies de qualité des données applique des algorithmes d'apprentissage automatique (ML) aux statistiques des données au fil du temps afin de détecter les modèles anormaux et les problèmes cachés de qualité des données difficiles à détecter par le biais de règles. Pour plus d'informations, consultez la section [Détection des anomalies dans AWS Glue Data Quality](#).

26 novembre 2023

[Mise à jour du comportement par défaut de journalisation de l'interface utilisateur Spark](#)

Les tâches Spark générant des journaux de l'interface utilisateur Spark seront désormais écrites avec un modèle de nom de fichier différent pour prendre en charge l'interface utilisateur Spark dans la AWS Glue console. Cela ne modifie pas le comportement du CloudWatch journal. Vous pouvez revenir à l'ancien comportement en mettant à jour la configuration de votre tâche. Pour plus d'informations, consultez la rubrique [Surveillance des tâches à l'aide de l'interface web d'Apache Spark](#).

17 novembre 2023

[Support pour les nouvelles sources de données dans AWS Glue Spark](#)

Les connexions à Amazon OpenSearch Service, Azure SQL, Azure Cosmos pour NoSQL, SAP HANA, Teradata Vantage et Vertica sont désormais prises en charge de manière native au sein de ce service. AWS Glue En outre, les connexions à ces sources de données, ainsi qu'à MongoDB, peuvent désormais être utilisées dans l'éditeur visuel de AWS Glue Studio. Pour plus d'informations, consultez [Types et options de connexion pour ETL dans Spark AWS Glue pour](#) plus d'informations sur AWS Glue le support de Spark et [Ajout d'une AWS Glue connexion](#) pour des informations sur l'utilisation dans l'éditeur visuel AWS Glue Studio.

17 novembre 2023

[Prise en charge de la génération de statistiques de colonne](#)

Vous pouvez calculer des statistiques au niveau des colonnes pour AWS Glue Data Catalog des tables dans des formats de données tels que Parquet, ORC, JSON, ION, CSV et XML sans configurer de pipelines de données supplémentaires. Pour plus d'informations, consultez [Utilisation des statistiques de colonne](#).

16 novembre 2023

[Prise en charge du compactage des données des tables Iceberg](#)

Pour améliorer les performances de lecture des services AWS d'analyse tels qu'Amazon Athena et Amazon EMR, ainsi que pour les tâches AWS Glue ETL, Data Catalog propose un compactage géré (un processus qui compacte de petits objets Amazon S3 en objets plus grands) pour les tables Iceberg dans Data Catalog. Pour plus d'informations, consultez [Optimisation des tables Iceberg](#).

13 novembre 2023

[Mise à jour du comportement d'attente lors de l'exécution des tâches](#)

Les exécutions de tâches standard du shell Spark et Python seront désormais transférées vers WAITING dans certaines situations, au lieu de passer immédiatement à FAILED. Pour plus d'informations, consultez la rubrique [États d'exécution des tâches AWS Glue](#).

8 novembre 2023

[AWS Glue Studio guide de l'utilisateur consolidé dans le guide AWS Glue du développeur](#)

Le guide de AWS Glue Studio l'utilisateur a été transféré dans le guide du développeur afin de créer un guide utilisateur unifié unique pour AWS Glue Studio la AWS Glue console et l'accès AWS Glue Studio par programmation.

25 octobre 2023

[Mise à jour de la politique
AWSGlue ServiceNo
tebookRole AWS gérée](#)

Ajout d'informations concernant une mise à jour mineure de la politique AWSGlue ServiceNo tebookRole AWS gérée. Pour plus d'informations, consultez la section [AWS Glue Mises à jour des politiques AWS gérées](#).

9 octobre 2023

[AWS Glue Studio prend
en charge cinq nouvelles
transformations intégrées](#)

AWS Glue Studio prend en charge les cinq nouvelles transformations intégrées suivantes : correspondance des enregistrements, suppression des lignes nulles, analyse de la colonne JSON, extraction du chemin JSON et extracteur Regex. Pour plus d'informations, consultez la section [Modification des nœuds de transformation de données AWS Glue gérés](#).

11 août 2023

[Mise à jour de la politique
AWSGlue ServiceRole AWS
gérée](#)

Ajout d'informations concernant une mise à jour mineure de la politique AWSGlue ServiceRole AWS gérée. Pour plus d'informations, voir [AWS Glue Mises à jour des politiques AWS gérées](#).

4 août 2023

[Prise en charge pour l'indexation de tables Apache Hudi](#)

Ajout d'informations sur l'utilisation AWS Glue pour explorer les tables Hudi dans les compartiments Amazon S3 et sur l'enregistrement des tables Hudi dans le. AWS Glue Data Catalog Pour plus d'informations, consultez [Which data stores can I crawl?](#), et [Crawler properties](#).

21 juillet 2023

[Mise à jour de la politique AWSGlue ConsoleFullAccess AWS gérée](#)

Ajout d'informations concernant une mise à jour mineure de la politique AWSGlue ConsoleFullAccess AWS gérée. Pour plus d'informations, consultez la section [AWS Glue Mises à jour des politiques AWS gérées](#).

14 juillet 2023

[Prise en charge pour l'indexation de tables Apache Iceberg](#)

Ajout d'informations sur l'utilisation AWS Glue pour explorer les tables Iceberg dans les compartiments Amazon S3 et sur l'enregistrement des tables Iceberg dans le. AWS Glue Data Catalog Pour plus d'informations, consultez [Which data stores can I crawl?](#), et [Crawler properties](#).

7 juillet 2023

[Support pour « AWS Glue with Ray »](#)

Ajout d'informations sur AWS Glue with Ray, un nouveau moteur qui permet de sauvegarder AWS Glue des jobs. Réorganisé l'existant AWS Glue avec du contenu Spark pour lever toute ambiguïté.

30 mai 2023

[Support pour la qualité AWS Glue des données \(GA\)](#)

AWS Glue La qualité des données est désormais généralement disponible. AWS Glue La qualité des données vous aide à évaluer et à contrôler la qualité de vos données. Pour plus d'informations sur l'utilisation de la qualité AWS Glue des données avec le catalogue de données, consultez la section [QualitéAWS Glue des données](#). Pour en savoir plus sur la qualité AWS Glue des données pour AWS Glue Studio, consultez la section [Évaluation de la qualité des données avec AWS Glue Studio](#).

24 mai 2023

[Prise en charge de types de travailleurs plus importants pour les tâches Apache Spark](#)

La prise en charge est désormais disponible pour l'utilisation des types de travailleurs G.4X et G.8X pour les tâches Apache Spark. Ces types de travailleurs sont appropriés pour les tâches dont les charges de travail contiennent les transformations, les agrégations, les jointures et les requêtes les plus exigeantes. Pour plus d'informations, consultez la section [Ajout de tâches AWS Glue](#).

8 mai 2023

[Prise en charge de la création d'index de partition lors de l'indexation de tables](#)

Ajout d'informations sur la manière dont les Crawlers prennent en charge la création d'index de partition pour les tables détectées par le Crawler. Pour plus d'informations, consultez [Setting the partition index crawler configuration option](#).

24 avril 2023

[Prise en charge des mesures d'utilisation des ressources](#)

Ajout d'informations sur l'affichage de l'utilisation des ressources du service et la configuration des alarmes dans Amazon CloudWatch. Pour plus d'informations, consulter [AWS Glue resource monitoring](#).

7 avril 2023

Mise à jour de la politique AWSGlue ConsoleFullAccess AWS gérée	Ajout d'informations concernant une mise à jour mineure de la politique AWSGlue ConsoleFullAccess AWS gérée. Pour plus d'informations, consultez la section AWS Glue Mises à jour des politiques AWS gérées .	28 mars 2023
Ajout de conseils d'utilisation AWS Glue avec un AWS SDK avec des exemples	Le guide du AWS Glue développeur comporte deux nouvelles sections qui fournissent des informations pour vous aider AWS Glue à utiliser un AWS SDK. Pour plus d'informations, consultez les sections Utilisation AWS Glue avec un AWS SDK et Exemples de code d' AWS Glue utilisation AWS SDKs .	23 février 2023
Mise à jour de la documentation pour IAM avec AWS Glue	Informations réorganisées et ajoutées sur l'utilisation d'IAM avec. AWS Glue Pour plus d'informations, veuillez consulter la rubrique Gestion des identités et des accès pour AWS Glue .	15 février 2023

[Support pour l'exécution de tâches ETL en streaming dans AWS Glue la version 4.0](#)

Ajout d'informations concernant la prise en charge de l'exécution de tâches ETL en streaming dans Glue version 4.0, et de nouvelles options de connexion à un cluster Kafka ou à un cluster Amazon Managed Streaming for Apache Kafka et Amazon Kinesis Data Streams. Pour plus d'informations, veuillez consulter les rubriques [Ajout de tâches ETL en streaming dans AWS Glue](#) et [Types et options de connexion pour ETL dans AWS Glue](#).

[Prise en charge de l'analyse des sources de données MongoDB Atlas](#)

Ajout d'informations sur l'utilisation AWS Glue pour explorer les sources de données MongoDB Atlas. Pour plus d'informations, voir [Quels magasins de données puis-je explorer ?](#), [propriétés de connexion MongoDB et MongoDB Atlas](#), et [Utilisation d'une connexion MongoDB ou MongoDB Atlas](#).

[Prise en charge de l'analyse des tables Delta Lake à l'aide d'un connecteur Delta Lake natif](#)

Ajout d'informations sur l'utilisation AWS Glue pour parcourir les tables de Delta Lake à l'aide d'un connecteur Delta Lake natif. Cette fonctionnalité vous permet d'utiliser des moteurs de AWS requête pour interroger directement le journal des transactions Delta et d'utiliser des fonctionnalités telles que le voyage dans le temps et les garanties ACID, et de synchroniser vos métadonnées Delta Lake à partir des fichiers de transactions Amazon S3 dans le catalogue de données afin d'activer les autorisations de colonne sur vos requêtes dans Lake Formation. Pour plus d'informations, veuillez consulter les rubriques [Comment préciser les options de configuration pour un magasin de données Delta Lake](#) et [Interrogation des tables Delta Lake](#).

15 décembre 2022

[Support pour la qualité AWS Glue des données \(version préliminaire\)](#)

Support est désormais disponible pour AWS Glue Data Quality (version préliminaire). AWS Glue La qualité des données vous permet d'évaluer et de contrôler la qualité de vos données lorsque vous utilisez la AWS Glue version 3.0. Pour plus d'informations sur l'utilisation de la qualité AWS Glue des données avec le catalogue de données, voir [QualitéAWS Glue des données \(version préliminaire\)](#). Pour en savoir plus sur la qualité AWS Glue des données pour AWS Glue Studio, consultez la section [Évaluation de la qualité des données avec AWS Glue Studio](#).

30 novembre 2022

[Prise en charge d'un nouveau connecteur Amazon Redshift Spark avec de nouvelles fonctionnalités et des améliorations de performances](#)

Support est désormais disponible pour un nouveau connecteur Amazon Redshift Spark doté d'un nouveau pilote JDBC à utiliser avec des tâches AWS Glue ETL afin de créer des applications Apache Spark capables de lire et d'écrire sur des données dans Amazon Redshift dans le cadre de vos pipelines d'ingestion et de transformation des données. Pour plus d'informations, consultez la rubrique [Moving data to and from Amazon Redshift](#) (Déplacement de données vers et depuis Amazon Redshift).

29 novembre 2022

[Support pour AWS Glue la version 4.0.](#)

Ajout d'informations sur le support de AWS Glue la version 4.0. Les fonctionnalités incluent la prise en charge native des infrastructures de lacs de données ouvertes avec Apache Hudi, Delta Lake et Apache Iceberg, ainsi que la prise en charge native du plug-in Cloud Shuffle Storage basé sur Amazon S3 (un plug-in Apache Spark) qui utilise Amazon S3 pour le brassage et une capacité de stockage élastique. Pour plus d'informations, consultez les [notes AWS Glue de publication](#) et [la migration des AWS Glue tâches vers la AWS Glue version 4.0.](#)

28 novembre 2022

[AWS Glue Studio propose désormais des transformations visuelles personnalisées](#)

Les transformations visuelles personnalisées permettent aux clients de définir, de réutiliser et de partager une logique ETL spécifique à l'entreprise avec leurs équipes. Pour plus d'informations, consultez [Custom visual transforms](#) (Transformations visuelles personnalisées).

28 novembre 2022

[Support pour l'utilisation du AWS Glue robot d'exploration pour publier des métadonnées pour les magasins de données JDBC](#)

Support est désormais disponible pour l'utilisation du AWS Glue robot d'exploration pour publier des métadonnées telles que des commentaires et des types bruts dans le catalogue de données pour les magasins de données JDBC. [Pour plus d'informations, voir Paramètres définis sur les tables du catalogue de données par robot, propriétés du robot et JdbcTarget structure.](#)

18 novembre 2022

[Prise en charge de l'indexation des magasins de données Snowflake](#)

Support est désormais disponible AWS Glue pour explorer les tables et les vues Snowflake et pour publier les métadonnées dans le catalogue de données sous forme d'entrée de table. Pour les tables externes Snowflake dans Amazon S3, le crawler analyse également l'emplacement Amazon S3 et le type de format de fichier de la table externe et les renseigne en tant que paramètres de table. Pour plus d'informations, consultez [Which data stores can I crawl?](#) (Quels magasins de données puis-je analyser ?), les [propriétés de connexion AWS Glue](#) et les [paramètres définis sur les tables du catalogue de données par un crawler](#).

18 novembre 2022

[Prise en charge d'une meilleure gestion du brassage de vos applications Spark](#)

Désormais, la prise en charge d'un nouveau plug-in Cloud Shuffle Storage pour Apache Spark est disponible. Pour plus d'informations, consultez [AWS Glue Spark shuffle plugin with Amazon S3](#) et [Cloud Shuffle Storage Plugin for Apache Spark](#).

15 novembre 2022

[Ajout de la prise en charge des cibles du catalogue de données lors de l'accélération des analyses \(notifications d'événements Amazon S3\)](#)

Outre le support existant pour les cibles Amazon S3, un support est désormais disponible pour accélérer les analyses des cibles du catalogue de données à l'aide des notifications d'événements Amazon S3. Pour en savoir plus, consultez [Accélération des analyses à l'aide des notifications d'événements Amazon S3](#).

13 octobre 2022

[Support permettant de spécifier le nombre maximum de tables qu'un crawler peut créer](#)

Le support est désormais disponible pour spécifier le nombre maximum de tables que le crawler est autorisé à créer. Pour plus d'informations, consultez la rubrique [Comment spécifier le nombre maximum de tables que le crawler est autorisé à créer](#).

6 septembre 2022

[Support de Python 3.9 dans les jobs shell Python dans AWS Glue](#)

Support est désormais disponible pour l'exécution de scripts compatibles avec Python 3.9 dans les jobs shell Python et pour le choix d'utiliser des ensembles de bibliothèques préemballés. AWS Glue Pour en savoir plus, consultez [Tâches Python shell dans AWS Glue](#).

11 août 2022

[Support pour exécuter des AWS Glue tâches non urgentes ou non urgentes avec des capacités inutilisées](#)

La prise en charge est désormais disponible pour la configuration d'exécutions de tâches flexibles pour les tâches non urgentes telles que les tâches de pré-production, les tests et les chargements de données ponctuels. Pour plus d'informations, consultez la section [Ajout de tâches AWS Glue](#).

9 août 2022

[Prise en charge d'un nouveau type d'employé pour les tâches de streaming](#)

Une prise en charge est désormais disponible pour une utilisation du type d'employé G.025X pour les tâches de streaming à faible volume. Pour plus d'informations, consultez la section [Ajout de tâches AWS Glue](#).

14 juillet 2022

[Support pour l'utilisation de Kafka SASL dans les connexions AWS Glue](#)

Support est désormais disponible pour l'utilisation de Kafka SASL dans les AWS Glue connexions. Pour plus d'informations, consultez [Propriétés de connexion Kafka AWS Glue pour l'authentification du client](#).

5 juillet 2022

[Prise en charge du connecteur Apache Kafka pour schémas Protobuf](#)

La prise en charge du connecteur Apache Kafka est désormais disponible pour schémas Protobuf. Pour plus d'informations, consultez [Registre de schémas AWS Glue](#).

9 juin 2022

Support pour Auto Scaling for AWS Glue jobs (GA)	Ajout d'informations sur l'utilisation d'Auto Scaling pour les tâches dans AWS Glue la version 3.0 afin de dimensionner dynamiquement les ressources de calcul. Pour plus d'informations, consultez Utilisation d'Auto Scaling pour AWS Glue .	14 avril 2022
Mise à jour de la documentation pour le AWS Glue développement et le test de scripts de AWS Glue travail	Informations réorganisées et ajoutées sur les méthodes de développement et de test disponibles pour AWS Glue, y compris les instructions pour le développement avec Docker. Pour plus d'informations, consultez la section Développement et test de scripts de AWS Glue travail .	14 mars 2022
Ajout de tampons de protocole (protobuf) en tant que format de données pris en charge pour le registre de schémas AWS Glue	Ajout d'informations sur Protobuf en tant que format de données pris en charge (en plus d'AVRO et de JSON). Pour plus d'informations, consultez Registre de schémas AWS Glue .	25 février 2022
Prise en charge des tables rampantes Delta Lake	Ajout d'informations sur l'utilisation AWS Glue pour parcourir les tables de Delta Lake. Pour plus d'informations, consultez Comment préciser les options de configuration pour un magasin de données Delta Lake .	24 février 2022

[Support pour obtenir des informations sur les AWS Glue offres d'emploi](#)

Ajout d'informations sur l'utilisation AWS Glue des informations sur les tâches pour simplifier le débogage des tâches et l'optimisation de vos AWS Glue tâches. Pour plus d'informations, consultez la section [Surveillance à l'aide des informations sur les AWS Glue emplois](#).

8 février 2022

[Prise en charge de l'analyse des tables du catalogue de données basées sur Amazon S3 à l'aide d'un point de terminaison d'un VPC](#)

En plus des magasins de données Amazon S3, vous pouvez configurer vos tables du catalogue de données basées sur Amazon S3 pour qu'ils soient accessibles uniquement par un environnement Amazon Virtual Private Cloud (Amazon VPC), à des fins de sécurité, d'audit ou de contrôle. Pour plus d'informations, consultez [Analyse d'un magasin de données Amazon S3 ou tables du catalogue de données basées sur Amazon S3 à l'aide d'un point de terminaison d'un VPC](#).

3 février 2022

[Support des tables régies de Lake Formation](#)

Ajout d'informations sur la AWS Glue prise en charge des tables gouvernées par Lake Formation, qui prennent en charge les transactions ACID, le compactage automatique des données et les requêtes de voyage dans le temps. Pour en savoir plus, consultez [API AWS Glue](#) et le [guide du développeur AWS Lake Formation](#).

30 novembre 2021

[Nouvelles politiques AWS gérées ajoutées pour les sessions interactives et les blocs-notes](#)

Les nouvelles politiques gérées pour IAM ont renforcé la sécurité lors de l'utilisation AWS Glue des sessions interactives et des blocs-notes. Pour plus d'informations, veuillez consulter la rubrique [Politiques gérées par AWS pour AWS Glue](#).

30 novembre 2021

[Registre de schémas Glue désormais supportés avec les tâches de streaming](#)

Vous pouvez créer des tâches de streaming qui accèdent aux tables qui font partie du registre de schéma Glue. Pour en savoir plus, consultez [Registre de schémas AWS Glue](#) et [Ajouter des tâches ETL de streaming dans AWS Glue](#).

15 novembre 2021

[Support des nouvelles fonctions de machine learning](#)

Ajout d'informations sur les nouvelles fonctions de transformation machine learning Recherche de correspondances, y compris la correspondance progressive et la notation des correspondances. Pour en savoir plus, consultez [Recherche de correspondances progressives](#) et [Estimation de la qualité des correspondances à l'aide des notes de confiance des correspondances](#).

31 octobre 2021

[\(Aperçu privé\) Support pour les jobs AWS Glue flexibles](#)

Ajout d'informations sur la configuration des tâches AWS Glue Spark avec une classe d'exécution flexible, adaptée aux tâches non urgentes dont les heures de début et de fin peuvent varier. Pour plus d'informations, consultez la section [Ajout de tâches AWS Glue](#).

29 octobre 2021

[Support d'accélération des explorations à l'aide des notifications d'événements Amazon S3](#)

Ajout d'informations sur l'accélération des explorations à l'aide des notifications d'événements Amazon S3. Pour en savoir plus, consultez [Accélération des explorations à l'aide des notifications d'événements Amazon S3](#).

15 octobre 2021

[Options de configuration de sécurité supplémentaires liées au contrôle d'accès et VPCs](#)

Ajout d'informations sur la façon dont vous pouvez configurer les nouvelles autorisations de contrôle d'accès AWS Glue et la configuration de VPCs. Pour plus d'informations, consultez les sections [AWS Balises AWS Glue](#), [politiques basées sur l'identité \(politiques IAM\) qui contrôlent les paramètres à l'aide de clés de condition ou de clés contextuelles](#), et [Configuration de tous les AWS appels pour qu'ils passent par votre VPC](#).

13 octobre 2021

[Support des politiques de point de terminaison d'un VPC](#)

Ajout d'informations sur le support des politiques de point de terminaison Virtual Private Cloud (VPC) dans AWS Glue. Pour en savoir plus, consultez la section relative à [AWS Glue et points de terminaison VPC d'interface \(AWS PrivateLink\)](#).

11 octobre 2021

[Glue Studio est désormais disponible en Chine](#)

AWS Glue Studio est désormais disponible dans les régions de Pékin et de Ningxia en Chine.

11 octobre 2021

[AWS Glue Studio propose la création de blocs-notes, pour une édition interactive des tâches](#)

Les blocs-notes vous permettent d'écrire et d'exécuter du code, de visualiser les résultats et de partager des informations. En général, les spécialistes des données utilisent des blocs-notes pour des expériences et des tâches d'exploration de données. Pour plus d'informations, consultez [Using Notebooks](#) (Utilisation des blocs-notes).

1er octobre 2021

[Un accès direct aux sources de streaming est désormais disponible](#)

Lorsque vous ajoutez des sources de données à votre tâche ETL dans l'éditeur visuel, vous pouvez fournir des informations pour accéder au flux de données au lieu d'utiliser une base de données et une table du catalogue de données.

30 septembre 2021

[A documenté la politique de support des AWS Glue versions](#)

Ajout d'informations sur la politique de support des AWS Glue versions et les phases de fin de vie de certaines AWS Glue versions. Pour en savoir plus, consultez [politique de prise en charge de version AWS Glue](#).

24 septembre 2021

[Les connecteurs personnalisés peuvent désormais être utilisés avec des prévisualisations de données](#)

Lorsque vous modifiez un nœud de source de données à l'aide d'un connecteur personnalisé, vous pouvez prévisualiser le jeu de données en cliquant sur l'onglet Aperçu des données. Pour plus d'informations, consultez [Custom Connectors](#) (Connecteurs personnalisés).

24 septembre 2021

[Support pour les sessions AWS Glue interactives \(aperçu privé\)](#)

(Aperçu privé) Ajout d'informations sur l'utilisation de sessions AWS Glue interactives pour exécuter des charges de travail Spark dans le cloud à partir de n'importe quel bloc-notes Jupyter. Les sessions interactives constituent la méthode préférée pour développer votre code AWS Glue d'extraction, de transformation et de chargement (ETL) lorsque vous utilisez la AWS Glue version 2.0 ou une version ultérieure. Pour plus d'informations, consultez [Configuration et exécution de sessions AWS Glue interactives pour Jupyter](#) Notebook.

24 août 2021

[Prise en charge de la création de flux de travail à partir de plans \(GA\)](#)

Ajout d'informations sur le codage des cas d'utilisation courants Extract-transform-load (ETL) dans les modèles, puis sur la création de flux de travail à partir de modèles. Permet aux analystes de données de créer et d'exécuter facilement des processus ETL complexes. Pour plus d'informations, consultez [Exécution d'activités ETL complexes à l'aide de plans et de flux de travail dans AWS Glue](#).

23 août 2021

[Support pour AWS Glue la version 3.0.](#)

Ajout d'informations sur la prise en charge de la AWS Glue version 3.0, qui prend en charge la mise à niveau du moteur Apache Spark 3.0 pour l'exécution des tâches ETL Apache Spark, ainsi que d'autres optimisations et mises à niveau. Pour plus d'informations, consultez les [notes AWS Glue de publication](#) et [la migration des AWS Glue tâches vers la AWS Glue version 3.0](#). Les autres fonctionnalités de cette version incluent le gestionnaire de AWS Glue shuffle, un lecteur CSV vectorisé SIMD et des prédicats de partition de catalogue. Pour plus d'informations, consultez [le gestionnaire de shuffle AWS Glue Spark avec Amazon S3](#), les [options de format pour les entrées et sorties ETL AWS Glue](#), et le [filtrage côté serveur à l'aide de prédicats](#) de partition de catalogue.

18 août 2021

[AWS GovCloud \(US\) Region](#)

AWS Glue Studio est désormais disponible dans AWS GovCloud (US) Region

18 août 2021

[La création de shell Python est disponible dans AWS Glue Studio](#)

Lors de la création d'une nouvelle tâche, vous pouvez maintenant choisir de créer une tâche shell Python. Pour en savoir plus, consultez [Start the job creation process](#) et [Editing Python shell jobs in AWS Glue Studio](#).

13 août 2021

[Support pour démarrer un flux de travail avec un EventBridge événement Amazon](#)

Ajout d'informations sur la manière d' AWS Glue être un consommateur d'événements dans une architecture axée sur les événements. Pour plus d'informations, consultez [Démarrer un AWS Glue flux de travail avec un EventBridge événement Amazon](#) et [Afficher les EventBridge événements qui ont démarré un flux de travail](#).

14 juillet 2021

[Ajout de JSON en tant que format de données pris en charge pour le registre de AWS Glue schémas](#)

Ajout d'informations sur JSON en tant que format de données pris en charge (en plus d'AVRO). Pour de plus amples informations, veuillez consulter [Registre de schémas AWS Glue](#).

30 Juin 2021

[Créez des tâches de AWS Glue streaming sans table de catalogue de données](#)

La fonction Python `create_data_frame_from_options` ou `getSource` pour les scripts Scala prennent en charge la création de tâches ETL en streaming qui référence nt directement les flux de données au lieu de nécessiter une table Data Catalog.

15 juin 2021

[AWS Glue l'apprentissage automatique transforme désormais les AWS Key Management Service clés de support](#)

Vous pouvez spécifier une configuration ou une AWS KMS clé de sécurité lorsque vous configurez des transformations de AWS Glue Machine Learning à l'aide de la console, de la CLI ou du AWS Glue APIs. Pour de plus amples informations, veuillez consulter [Utilisation du chiffrement des données avec les transformations de machine learning](#) et [API de machine learning AWS Glue](#).

15 juin 2021

[Mise à jour de la politique AWSGlue ConsoleFullAccess AWS gérée](#)

Ajout d'informations concernant une mise à jour mineure de la politique AWSGlue ConsoleFullAccess AWS gérée. Pour plus d'informations, voir [AWS Glue Mises à jour des politiques AWS gérées](#).

10 juin 2021

[Afficher le jeu de données de votre tâche lors de la création et de la modification des tâches](#)

Vous pouvez utiliser le nouveau module Data preview (Prévisualisation des données) d'un nœud dans votre diagramme de tâche pour afficher un échantillon des données traitées par ce nœud. Pour de plus amples informations, veuillez consulter la rubrique [Utilisation des prévisualisations de données dans l'éditeur de tâches visuel](#).

7 juin 2021

[Prise en charge de la spécification d'une valeur qui indique l'emplacement de la table pour la sortie du crawler.](#)

Ajout d'informations sur la spécification d'une valeur indiquant l'emplacement de la table lors de la configuration de la sortie du crawler. Pour de plus amples informations, veuillez consulter [Procédure pour spécifier l'emplacement de la table](#).

4 juin 2021

[Prise en charge de l'analyse d'un échantillon de fichiers dans un jeu de données lors de l'exploration d'un magasin de données Amazon S3](#)

Ajout d'informations sur l'analyse d'un échantillon de fichiers lors de l'analyse d'Amazon S3. Pour plus d'informations, consultez [Propriétés de l'crawler](#).

10 mai 2021

[Support pour le parquettiste AWS Glue optimisé](#)

Ajout d'informations sur l'utilisation du rédacteur de parquet AWS Glue optimisé DynamicFrames pour créer ou mettre à jour des tableaux avec la parquet classification. Pour plus d'informations, voir [Création de tables, mise à jour du schéma et ajout de nouvelles partitions dans le catalogue de données à partir de tâches AWS Glue ETL et Options de format pour les entrées et sorties ETL dans AWS Glue.](#)

4 mai 2021

[Prise en charge des mots de passe pour l'authentification du client Kafka](#)

Ajout d'informations sur la façon dont le streaming de tâches ETL AWS Glue prend en charge l'authentification par certificat client SSL auprès des producteurs de flux Apache Kafka. Vous pouvez désormais fournir un certificat personnalisé lors de la définition d'une AWS Glue connexion à un cluster Apache Kafka, qui AWS Glue sera utilisé lors de l'authentification auprès de celui-ci. Pour plus d'informations, consultez [Propriétés de connexion AWS Glue](#) et [API de connexion.](#)

28 avril 2021

[Prise en charge de la consommation de données d'Amazon Kinesis Data Streams dans un autre compte dans les tâches ETL de streaming](#)

Ajout d'informations sur la création d'une tâche ETL de streaming pour consommer les données d'Amazon Kinesis Data Streams dans un autre compte. Pour plus d'informations, consultez la section [Ajout de tâches ETL en streaming dans AWS Glue](#).

30 mars 2021

[Transformation SQL disponible](#)

Vous pouvez utiliser un nœud de transformation SQL pour écrire votre propre transformation sous la forme d'une requête SQL. Pour de plus amples informations, veuillez consulter la rubrique [Utilisation d'une requête SQL pour transformer des données](#).

23 mars 2021

[Prise en charge de la création de flux de travail à partir de plans \(version préliminaire publique\)](#)

(Version préliminaire publique)
Ajout d'informations sur le codage des cas d'utilisation courants Extract-transform-load (ETL) dans les modèles, puis sur la création de flux de travail à partir de modèles. Permet aux analystes de données de créer et d'exécuter facilement des processus ETL complexes. Pour plus d'informations, consultez [Exécution d'activités ETL complexes à l'aide de plans et de flux de travail dans AWS Glue](#).

22 mars 2021

[Les connecteurs peuvent être utilisés pour les cibles de données](#)

L'utilisation d'un AWS Marketplace connecteur ou d'un personnalisé pour votre cible de données est désormais prise en charge. Pour de plus amples informations, veuillez consulter la rubrique [Création de tâches avec des connecteurs personnalisés](#).

15 mars 2021

[Support des indicateurs d'importance des colonnes pour les transformations du AWS Glue machine learning](#)

Ajout d'informations sur l'affichage des indicateurs d'importance des colonnes lors de l'utilisation de transformations basées sur le AWS Glue machine learning. Pour plus d'informations, voir [Utilisation des transformations du Machine Learning sur la AWS Glue console](#)

5 février 2021

[La planification des tâches est désormais disponible dans AWS Glue Studio](#)

Vous pouvez définir une planification temporelle pour l'exécution de vos tâches dans AWS Glue Studio. Vous pouvez utiliser la console pour créer une planification de base, ou définir une planification plus complexe à l'aide de la syntaxe de type Unix [cron](#). Pour de plus amples informations, veuillez consulter la rubrique [Planification des exécutions de tâches](#).

21 décembre 2020

[AWS Glue Connecteurs personnalisés publiés](#)

AWS Glue Les connecteurs personnalisés vous permettent de découvrir et de vous abonner à des connecteurs dans AWS Marketplace. Nous avons également publié des interfaces d'exécution AWS Glue Spark pour intégrer des connecteurs conçus pour Apache Spark DataSource, Athena federated Query et JDBC. APIs Pour plus d'informations, consultez la section [Utilisation de connecteurs et de connexions avec AWS Glue Studio](#).

21 décembre 2020

[Support pour l'exécution de tâches ETL en streaming dans AWS Glue la version 2.0](#)

Ajout d'informations sur la prise en charge de l'exécution de tâches ETL en streaming dans Glue version 2.0. Pour plus d'informations, consultez la section [Ajout de tâches ETL en streaming dans AWS Glue](#).

18 décembre 2020

[Prise en charge du partitionnement de la charge de travail avec exécution limitée](#)

Ajout d'informations sur l'activation du partitionnement de la charge de travail pour configurer les limites supérieures de la taille du jeu de données ou du nombre de fichiers traités lors des exécutions de tâches ETL. Pour de plus amples informations, veuillez consulter [Partitionnement de la charge de travail avec exécution limitée](#).

23 novembre 2020

[Prise en charge de la gestion améliorée des partitions](#)

Ajout d'informations sur la façon d'utiliser new APIs pour ajouter ou supprimer un index de partition vers/ depuis une table existante . Pour plus d'informations, consultez [Utilisation des index de partition](#).

23 novembre 2020

[Support pour le registre des AWS Glue schémas](#)

Ajout d'informations sur l'utilisation du registre des AWS Glue schémas pour découvrir , contrôler et faire évoluer les schémas de manière centralisée. Pour plus d'informations, consultez la section [Registre des AWS Glue schémas](#).

19 novembre 2020

[Prise en charge du format de saisie de Grok dans les tâches ETL de streaming](#)

Ajout d'informations sur l'application de modèles Grok aux sources de streaming telles que les fichiers journaux. Pour de plus amples informations, veuillez consulter [Application de modèles Grok à des sources de streaming](#).

17 novembre 2020

[Support pour l'ajout de balises aux flux de travail sur la AWS Glue console](#)

Ajout d'informations sur l'ajout de balises lors de la création d'un flux de travail à l'aide de la console AWS Glue . Pour plus d'informations, voir [Création et développement d'un flux de travail à l'aide de la AWS Glue console](#).

27 octobre 2020

[Prise en charge des exécutions progressives du crawler](#)

Ajout d'informations sur la prise en charge des exécutions incrémentielles du crawler, qui n'analysent que les dossiers Amazon S3 ajoutés depuis la dernière exécution. Pour de plus amples informations, veuillez consulter [Analyses incrémentielles](#).

21 octobre 2020

[Prise en charge de la détection de schéma pour les sources de données ETL en streaming. Prise en charge des sources de données ETL en streaming Avro et Kafka autogéré](#)

Les tâches d'extraction, de transformation et de chargement (ETL) en streaming AWS Glue peuvent désormais détecter automatiquement le schéma des enregistrements entrants et gérer les modifications de schéma par enregistrement. Les sources de données Kafka autogérées sont désormais prises en charge. Les tâches ETL en streaming prennent désormais en charge le format Avro dans les sources de données. Pour plus d'informations, consultez [Streaming ETL in AWS Glue](#), [Defining Job Properties for a Streaming ETL Job](#) et [Remarques et restrictions pour les sources de streaming Avro](#).

7 octobre 2020

[Prise en charge de l'analyse des sources de données MongoDB et DocumentDB](#)

Ajout d'informations sur la prise en charge de l'analyse des sources de données MongoDB et Amazon DocumentDB (avec compatibilité MongoDB). Pour plus d'informations, consultez [Définition des crawlers](#).

5 octobre 2020

[Prise en charge de la conformité FIPS](#)

Ajout d'informations sur les points de terminaison FIPS pour les clients qui ont besoin de modules cryptographiques validés FIPS 140-2 lors de l'accès aux données à l'aide de AWS Glue. Pour plus d'informations, consultez [Conformité FIPS](#).

23 septembre 2020

[AWS Glue Studio fournit une interface visuelle facile à utiliser pour la création et le suivi des emplois](#)

Vous pouvez désormais utiliser une interface graphique simple pour composer des tâches qui déplacent et transforment les données et les exécutent sur AWS Glue. Vous pouvez ensuite utiliser le tableau de bord d'exécution des tâches dans AWS Glue Studio pour contrôler l'exécution ETL et vous assurer que vos tâches fonctionnent comme prévu. Pour plus d'informations, consultez [.AWS Glue Studio Guide](#) de l'utilisateur

23 septembre 2020

[Prise en charge de la création d'index de tableau pour améliorer les performances des requêtes](#)

Ajout d'informations sur la création d'index de table pour vous permettre de récupérer un sous-ensemble des partitions d'une table. Pour plus d'informations, consultez [Utilisation des index de partition](#).

9 septembre 2020

[Support de temps de démarrage réduits lors de l'exécution de tâches ETL Apache Spark dans la version 2.0 de AWS Glue.](#)

Ajout d'informations sur la prise en charge de la AWS Glue version 2.0, qui fournit une infrastructure améliorée pour exécuter des tâches ETL Apache Spark avec des temps de démarrage réduits, des modifications dans la journalisation et la prise en charge de la spécification de modules Python supplémentaires au niveau des tâches. Pour de plus amples informations, veuillez consulter [Notes de mise à jour AWS Glue](#) et [Exécution de tâches ETL Spark avec des temps de démarrage réduits.](#)

10 août 2020

[Prise en charge de la limitation du nombre d'exécutions de flux de travail simultanées.](#)

Ajout d'informations sur la manière de limiter le nombre d'exécutions de flux de travail simultanées pour un flux de travail particulier. Pour plus d'informations, voir [Création et développement d'un flux de travail à l'aide de la AWS Glue console.](#)

10 août 2020

[Prise en charge de l'analyse d'un stock de données Amazon S3 à l'aide d'un point de terminaison d'un VPC](#)

Ajout d'informations sur la configuration de votre magasin de données Amazon S3 pour qu'il soit accessible uniquement par un environnement Amazon Virtual Private Cloud (Amazon VPC), à des fins de sécurité, d'audit ou de contrôle. Pour de plus amples informations, veuillez consulter [Analyse d'un magasin de données Amazon S3 à l'aide d'un point de terminaison VPC.](#)

7 août 2020

[Prise en charge de la reprise des exécutions de flux de travail](#)

Ajout d'informations sur la façon de reprendre les exécutions de flux de travail qui ne se sont que partiellement terminées, car un ou plusieurs nœuds (tâches ou crawlers) ne se sont pas terminés avec succès. Pour plus d'informations, consultez [Réparer et reprendre l'exécution d'un flux de travail.](#)

27 juillet 2020

[Prise en charge de l'activation des certificats d'autorité de certification privés dans les connexions Kafka au format AWS Glue.](#)

Ajout d'informations sur les nouvelles options de connexion qui prennent en charge l'activation des certificats d'autorité de certification privés pour les connexions Kafka dans AWS Glue. Pour plus d'informations, voir [Types de connexion et options pour l'ETL dans AWS Glue](#) et [Paramètres spéciaux utilisés par AWS Glue.](#)

20 juillet 2020

[Prise en charge de la lecture des données DynamoDB dans un autre compte](#)

Ajout d'informations sur la AWS Glue prise en charge de la lecture de données depuis la table DynamoDB d'un autre AWS compte. Pour plus d'informations, voir [Lecture à partir de données DynamoDB](#) dans un autre compte.

17 juillet 2020

[Support pour une connexion d'enregistreur DynamoDB AWS Glue dans la version 1.0 ou ultérieure](#)

Ajout d'informations sur la prise en charge de l'écriture DynamoDB et des options de connexion nouvelles ou mises à jour pour la lecture ou l'écriture de DynamoDB. Pour plus d'informations, veuillez consulter [Types de connexion et options de connexion pour ETL dans AWS Glue.](#)

17 juillet 2020

[Prise en charge des liens de ressources et du contrôle d'accès entre différents comptes en utilisant à la fois AWS Glue et Lake Formation](#)

Ajout de contenu sur les nouveaux objets du catalogue de données appelés liens de ressources, et sur la façon de gérer le partage des ressources du catalogue de données entre les comptes avec AWS Glue les deux AWS Lake Formation. Pour de plus amples informations, veuillez consulter [Octroi d'un accès intercompte](#) et [Liens de ressources de table](#).

7 juillet 2020

[Prise en charge des registres d'échantillonnage lors de l'analyse des stocks de données DynamoDB](#)

Ajout d'informations sur les nouvelles propriétés que vous pouvez configurer lors de l'analyse d'un magasin de données DynamoDB. Pour plus d'informations, consultez [Propriétés de l'crawler](#).

12 juin 2020

[Prise en charge de l'arrêt d'une exécution de flux de travail.](#)

Ajout d'informations sur la façon d'arrêter le cycle d'un flux de travail spécifique. Pour plus d'informations, consultez [Arrêt d'un cycle de flux de travail](#).

14 mai 2020

[Prise en charge des tâches ETL Spark Streaming](#)

Ajout d'informations sur la création de tâches d'extraction, de transformation et de chargement (ETL) avec des sources de données en streaming. Pour de plus amples informations, consultez [Ajout de tâches ETL en streaming dans AWS Glue.](#)

27 avril 2020

[Prise en charge de la création de tableaux, de la mise à jour du schéma et de l'ajout de nouvelles partitions dans le catalogue de données après l'exécution d'une tâche ETL](#)

Ajout d'informations sur la façon dont vous pouvez activer la création de tables, la mise à jour du schéma et l'ajout de nouvelles partitions pour afficher les résultats de votre tâche ETL dans le catalogue de données. Pour plus d'informations, voir [Création de tables, mise à jour du schéma et ajout de nouvelles partitions dans le catalogue de données à partir de tâches AWS Glue ETL.](#)

2 avril 2020

[Support pour la spécification d'une version pour le format de données Apache Avro en tant qu'entrée et sortie ETL dans AWS Glue](#)

Ajout d'informations sur la spécification d'une version pour le format de données Apache Avro en tant qu'entrée et sortie ETL dans AWS Glue. Version par défaut 1.7. Vous pouvez utiliser l'option de format `version` pour spécifier à Avro 1.8 d'activer la lecture/écriture logique. Pour plus d'informations, consultez la section [Options de format pour les entrées et sorties ETL dans AWS Glue](#).

31 mars 2020

[Prise en charge du validateur EMRFS optimisé pour S3 dans le cadre de l'écriture de données Parquet dans Amazon S3](#)

Ajout d'informations sur la façon de définir un nouvel indicateur pour activer le validateur EMRFS optimisé pour S3 dans le cadre de l'écriture de données Parquet sur Amazon S3 lors de la création ou de la mise à jour d'une tâche AWS Glue . Pour plus d'informations, consultez la section [Paramètres spéciaux utilisés par AWS Glue](#).

30 mars 2020

[Support à l'apprentissage automatique : transformation en tant que ressource gérée par AWS des balises de ressources](#)

Des informations supplémentaires sur l'utilisation de balises de AWS ressources pour gérer et contrôler l'accès à votre machine learning se transforment AWS Glue. Vous pouvez attribuer AWS des balises de ressources aux tâches, aux déclencheurs, aux points de terminaison, aux robots d'exploration et aux transformations de machine learning. AWS Glue Pour plus d'informations, consultez la section [AWS Tags in AWS Glue](#).

2 mars 2020

[Prise en charge des arguments de tâche non substituables](#)

Ajout d'informations sur la prise en charge des paramètres de tâche spéciaux qui ne peuvent pas être remplacés dans les déclencheurs ou lorsque vous exécutez la tâche. Pour plus d'informations, consultez [Ajout de tâches dans AWS Glue](#).

12 février 2020

[Prise en charge des nouvelles transformations pour l'utilisation des jeux de données dans Amazon S3](#)

Ajout d'informations sur les nouvelles transformations (Fusion, Purge et Transition) et sur les exclusions de classe de stockage Amazon S3 pour les applications Apache Spark dans le cadre de l'utilisation des ensembles de données dans Amazon S3. Pour plus d'informations sur la prise en charge de ces transformations pour Python, consultez la section [Utilisation mergeDyna micFrames des ensembles de données dans Amazon S3](#). Pour Scala, voir [mergeDyna micFrames](#) et [AWS Glue Scala GlueContext APIs](#).

16 janvier 2020

[Prise en charge de la mise à jour du catalogue de données avec les informations des nouvelles partitions à partir d'une tâche ETL](#)

Ajout d'informations sur la façon de coder un script d'extraction, de transformation et de chargement (ETL) pour mettre à jour les informations de partition AWS Glue Data Catalog avec de nouvelles informations. Avec cette fonctionnalité, vous n'avez plus besoin de réexécuter le crawler à la fin de la tâche pour afficher les nouvelles partitions. Pour plus d'informations, consultez [Mise à jour de Data Catalog avec de nouvelles partitions](#).

15 janvier 2020

[Nouveau tutoriel : Utilisation d'un bloc-notes basé sur SageMaker l'IA](#)

Ajout d'un didacticiel qui explique comment utiliser un SageMaker bloc-notes Amazon pour développer vos scripts ETL et d'apprentissage automatique. Consultez le [didacticiel : utilisez un SageMaker bloc-notes Amazon avec votre terminal de développement](#).

3 janvier 2020

[Prise en charge de la lecture depuis MongoDB et Amazon DocumentDB \(avec compatibilité MongoDB\)](#)

Ajout d'informations sur les nouveaux types de connexion et options de connexion pour la lecture et l'écriture dans MongoDB et Amazon DocumentDB (avec compatibilité MongoDB). Pour plus d'informations, veuillez consulter [Types de connexion et options de connexion pour ETL dans AWS Glue](#).

17 décembre 2019

[Corrections et clarifications diverses](#)

Des corrections et des clarifications ont été ajoutées. Des entrées ont été supprimées du chapitre Problèmes connus. Ajout d'avertissements qui ne prennent AWS Glue en charge que les clés principales symétriques du client (CMKs) lors de la spécification des paramètres de chiffrement du catalogue de données et de la création de configurations de sécurité. Ajout d'une note qui AWS Glue ne prend pas en charge l'écriture sur Amazon DynamoDB.

9 décembre 2019

[Prise en charge des pilotes JDBC personnalisés](#)

Ajout d'informations sur la connexion aux sources de données et aux cibles à l'aide de pilotes JDBC qui AWS Glue ne sont pas pris en charge de manière native, tels que MySQL version 8 et Oracle Database version 18. Pour plus d'informations, consultez [JDBC connectionType Values](#).

25 novembre 2019

[Support pour connecter des ordinateurs portables SageMaker dotés d'intelligence artificielle à différents terminaux de développement](#)

Ajout d'informations sur la façon dont vous pouvez connecter un bloc-notes SageMaker AI à différents terminaux de développement. Mises à jour pour décrire la nouvelle action de la console pour passer à un nouveau point de terminaison de développement, ainsi que la nouvelle politique SageMaker AI IAM. Pour plus d'informations, consultez les sections [Utilisation des blocs-notes sur la AWS Glue console](#) et [Création d'une politique IAM pour les blocs-notes Amazon SageMaker AI](#).

21 novembre 2019

[Support des AWS Glue versions lors des transformations liées à l'apprentissage automatique](#)

Ajout d'informations sur la définition de la AWS Glue version dans une transformation d'apprentissage automatique pour indiquer la version compatible avec laquelle AWS Glue une transformation d'apprentissage automatique est compatible. Pour plus d'informations, voir [Travailler avec les transformations du Machine Learning sur la AWS Glue console](#).

21 novembre 2019

[Prise en charge de la restauration de vos favoris de tâche](#)

Ajout d'informations sur la restauration de vos marque-pages de tâche sur une exécution de tâche précédente, ce qui entraîne le retraitement des données de l'exécution de tâche suivante uniquement à partir de l'exécution de travail marquée en favori. Décrit deux nouvelles sous-options pour l'option `job-bookmark-pause`, qui vous permettent d'exécuter une tâche entre deux favoris. Pour plus d'informations, voir [Suivi des données traitées à l'aide des signets de tâches et des paramètres spéciaux utilisés par AWS Glue.](#)

22 octobre 2019

[Prise en charge des certificats JDBC personnalisés pour la connexion à un stock de données](#)

Ajout d'informations sur la AWS Glue prise en charge des certificats JDBC personnalisés pour les connexions SSL aux sources de AWS Glue données ou aux cibles. Pour plus d'informations, consultez [Utilisation des connexions sur la console AWS Glue.](#)

10 octobre 2019

[Prise en charge de Python wheel](#)

Ajout d'informations sur la prise en AWS Glue charge des fichiers wheel (ainsi que des fichiers egg) en tant que dépendances pour les tâches shell Python. Pour plus d'informations, consultez [Ajout de votre propre bibliothèque Python](#).

26 septembre 2019

[Support pour le versionnement des terminaux de développement dans AWS Glue](#)

Ajout d'informations sur la définition des points de terminaison Glue version en cours de développement. Glue version détermine les versions d'Apache Spark et de Python prises AWS Glue en charge. Pour plus d'informations, consultez [Ajout d'un point de terminaison de développement](#).

19 septembre 2019

[Support pour la surveillance à AWS Glue l'aide de l'interface utilisateur Spark](#)

Ajout d'informations sur l'utilisation de l'interface utilisateur d'Apache Spark pour surveiller et déboguer les tâches AWS Glue ETL exécutées sur le système de AWS Glue tâches, ainsi que sur les applications Spark sur les points de terminaison de AWS Glue développement. Pour plus d'informations, consultez la section [Surveillance à AWS Glue l'aide de l'interface utilisateur Spark](#).

19 septembre 2019

[Amélioration de la prise en charge du développement de script ETL local à l'aide de la AWS Glue bibliothèque ETL publique](#)

Le contenu de la bibliothèque que AWS Glue ETL a été mis à jour pour indiquer que AWS Glue la version 1.0 est désormais prise en charge. Pour plus d'informations, voir [Développement et test de scripts ETL localement à l'aide de la bibliothèque AWS Glue ETL](#).

18 septembre 2019

[Prise en charge de l'exclusion des classes de stockage Amazon S3 lors de l'exécution de tâches](#)

Ajout d'informations sur l'exclusion des classes de stockage Amazon S3 lors de l'exécution de tâches AWS Glue ETL qui lisent des fichiers ou des partitions depuis Amazon S3. Pour de plus amples informations, veuillez consulter [Exclusion des classes de stockage Amazon S3](#).

29 août 2019

[Support pour le développement de scripts ETL locaux à l'aide de la bibliothèque AWS Glue ETL publique](#)

Ajout d'informations sur la façon de développer et de tester des scripts ETL Python et Scala localement sans avoir besoin d'une connexion réseau. Pour plus d'informations, voir [Développement et test de scripts ETL localement à l'aide de la bibliothèque AWS Glue ETL](#).

28 août 2019

Problèmes connus	Ajout d'informations sur les problèmes connus liés à AWS Glue. Pour plus d'informations, consultez Problèmes connus liés à AWS Glue .	28 août 2019
Support à l'apprentissage automatique se transforme AWS Glue	Ajout d'informations sur les fonctionnalités d'apprentissage automatique fournies par AWS Glue pour créer des transformations personnalisées. Vous pouvez créer ces transformations lorsque vous créez une tâche. Pour plus d'informations, consultez Machine Learning Transforms in AWS Glue .	8 août 2019
Prise en charge du cloud privé virtuel partagé d'Amazon	Ajout d'informations sur la AWS Glue prise en charge du partage d'Amazon Virtual Private Cloud. Pour plus d'informations, consultez Shared Amazon VPCs .	6 août 2019
Support pour la gestion des versions dans AWS Glue	Ajout d'informations sur la définition Glue version des propriétés de la tâche. AWS Glue version détermine les versions d'Apache Spark et de Python prises AWS Glue en charge. Pour plus d'informations, consultez la section Ajout de tâches AWS Glue .	24 juillet 2019

[Prise en charge d'options de configuration supplémentaires pour les points de terminaison de développement](#)

Ajout d'informations sur les options de configuration pour les points de terminaison de développement ayant des charges de travail gourmandes en mémoire. Vous avez le choix entre deux nouvelles configurations qui offrent une plus grande capacité de mémoire par exécuteur. Pour plus d'informations, consultez la section [Utilisation des points de terminaison de développement sur la AWS Glue console](#).

24 juillet 2019

[Prise en charge de l'exécution d'activités d'extraction, de transfert et de chargement \(ETL\) à l'aide de flux de travail](#)

Ajout d'informations sur l'utilisation d'une nouvelle structure appelée flux de travail pour concevoir une activité complexe d'extraction, de transformation et de chargement (ETL) multi-tâches AWS Glue pouvant être exécutée et suivie en tant qu'entité unique. Pour plus d'informations, voir [Exécution d'activités ETL complexes à l'aide de flux de travail dans AWS Glue](#).

20 juin 2019

[Prise en charge de Python 3.6 dans les tâches shell Python](#)

Ajout d'informations sur la prise en charge de Python 3.6 dans les tâches shell Python. Vous pouvez spécifier Python 2.7 ou Python 3.6 en tant que propriété de tâche. Pour en savoir plus, consultez [Ajout de tâches shell Python dans AWS Glue](#).

5 juin 2019

[Prise en charge des points de terminaison du Virtual Private Cloud \(VPC\)](#)

Ajout d'informations sur la connexion directe AWS Glue via un point de terminaison d'interface dans votre VPC. Lorsque vous utilisez un point de terminaison d'interface VPC, la communication entre votre VPC et celui-ci AWS Glue s'effectue entièrement et en toute sécurité au sein du réseau. AWS Pour plus d'informations, consultez la section [Utilisation AWS Glue avec des points de terminaison VPC](#).

4 juin 2019

[Support pour l'enregistrement continu et en temps réel des AWS Glue tâches.](#)

Ajout d'informations sur l'activation et l'affichage des journaux des tâches Apache Spark en temps réel, CloudWatch notamment les journaux des pilotes, les journaux de chacun des exécuteurs et une barre de progression des tâches Spark. Pour plus d'informations, consultez [Journalisation continue des tâches AWS Glue.](#)

28 mai 2019

[Prise en charge des tableaux du catalogue de données existantes en tant que sources du crawler](#)

Ajout d'informations sur la spécification d'une liste des tables Data Catalog existantes en tant que sources du crawler. Les crawlers peuvent ensuite détecter des modifications apportées aux schémas de table, mettre à jour les définitions de table et enregistrer de nouvelles partitions au fur et à mesure que de nouvelles données sont disponibles. Pour plus d'informations, consultez [Propriétés de l'crawler.](#)

10 mai 2019

[Prise en charge des options de configuration supplémentaires pour les tâches gourmandes en mémoire](#)

Ajout d'informations sur les options de configuration pour les tâches Apache Spark avec des charges de travail gourmandes en mémoire. Vous avez le choix entre deux nouvelles configurations qui offrent une plus grande capacité de mémoire par exécuteur. Pour plus d'informations, consultez la section [Ajout de tâches AWS Glue](#).

5 avril 2019

[Prise en charge de classifieurs personnalisés CSV](#)

Ajout d'informations sur l'utilisation d'un classifieur CSV personnalisé pour déduire le schéma de différents types de données CSV. Pour plus d'informations, consultez [Écriture de classifieurs personnalisés](#).

26 mars 2019

[Support pour les balises AWS de ressources](#)

Ajout d'informations sur l'utilisation AWS des balises de ressources pour vous aider à gérer et à contrôler l'accès à vos AWS Glue ressources. Vous pouvez attribuer AWS des balises de ressources aux tâches, aux déclencheurs, aux points de terminaison et aux robots d'exploration dans AWS Glue. Pour plus d'informations, consultez la section [AWS Tags in AWS Glue](#).

20 mars 2019

[Prise en charge du catalogue de données pour les tâches Spark SQL](#)

Ajout d'informations sur la configuration de vos AWS Glue tâches et de vos points de terminaison de développement pour les utiliser AWS Glue Data Catalog en tant que métastore Apache Hive externe. Ceci permet aux tâches et points de terminaison de développement d'exécuter directement des requêtes Apache Spark SQL sur les tables stockées dans le catalogue de données AWS Glue Data Catalog. Pour plus d'informations, consultez [Prise en charge de AWS Glue Data Catalog des tâches Spark SQL](#).

14 mars 2019

[Prise en charge des tâches shell Python](#)

Ajout d'informations sur les tâches shell Python et le nouveau champ Maximum capacity (Capacité maximum). Pour en savoir plus, consultez [Ajout de tâches shell Python dans AWS Glue](#).

18 janvier 2019

[Prise en charge des notifications en cas de modification des bases de données et des tableaux](#)

Ajout d'informations sur les événements qui sont générés en cas de modification au niveau des appels d'API des bases de données, tables et partitions. Vous pouvez configurer des actions dans CloudWatch Events pour répondre à ces événements. Pour plus d'informations, consultez [Automatisation à l'AWS Glue aide d' CloudWatch événements](#).

16 janvier 2019

[Prise en charge du chiffrement de mots de passe de connexion](#)

Ajout d'informations concernant le chiffrement de mots de passe utilisés dans les objets de connexion. Pour plus d'informations, consultez [Chiffrement des mots de passe de connexion](#).

11 décembre 2018

[Prise en charge des autorisations au niveau des ressources et des politiques basées sur les ressources](#)

Ajout d'informations sur l'utilisation des autorisations au niveau des ressources et des politiques basées sur les ressources avec AWS Glue. Pour plus d'informations, consultez les rubriques répertoriées dans [Sécurité dans AWS Glue](#).

15 octobre 2018

[Support pour les ordinateurs portables SageMaker dotés d'intelligence artificielle](#)

Ajout d'informations sur l'utilisation de blocs-notes SageMaker IA avec des terminaux AWS Glue de développement. Pour plus d'informations, consultez [Gestion des blocs-notes](#).

5 octobre 2018

[Prise en charge du chiffrement](#)

Ajout d'informations sur l'utilisation du chiffrement avec AWS Glue. Pour de plus amples informations, veuillez consulter [Chiffrement au repos](#), [Chiffrement en transit](#) et [Configuration du chiffrement dans AWS Glue](#).

24 août 2018

[Prise en charge des métriques de tâches Apache Spark](#)

Informations supplémentaires sur l'utilisation des métriques Apache Spark pour un meilleur débogage et un meilleur profilage des tâches ETL. Vous pouvez facilement suivre les indicateurs d'exécution tels que les octets lus et écrits, l'utilisation de la mémoire et la charge du processeur du pilote et des exécuteurs, ainsi que les transferts de données entre les exécuteurs depuis la console. AWS Glue Pour plus d'informations, consultez les [sections Surveillance AWS Glue à l'aide de CloudWatch métriques, Surveillance et débogage des tâches, et Utilisation des tâches sur la AWS Glue console.](#)

13 juillet 2018

[Prise en charge de DynamoDB en tant que source de données](#)

Informations supplémentaires sur l'indexation de DynamoDB et sur son utilisation en tant que source de données de tâches ETL. Pour plus d'informations, consultez [Catalogage de tables avec un crawler](#) et [Paramètres de connexion.](#)

10 juillet 2018

[Mises à jour pour créer une procédure de serveur de bloc-notes](#)

Informations mises à jour sur la création d'un serveur de blocs-notes sur une EC2 instance Amazon associée à un point de terminaison de développement. Pour plus d'informations, consultez [Création d'un serveur de bloc-notes associé à un point de terminaison de développement](#).

9 juillet 2018

[Mises à jour disponibles sur RSS](#)

Vous pouvez à présent vous abonner à un flux RSS pour recevoir les notifications des mises à jour du Guide du développeur AWS Glue .

25 juin 2018

[Prise en charge des notifications de délai d'attente pour les tâches](#)

Ajout d'informations sur la configuration d'un seuil de délai d'attente lorsqu'une tâche est exécutée. Pour plus d'informations, consultez [Ajout de tâches dans AWS Glue](#).

25 mai 2018

[Configuration d'un crawler pour ajouter de nouvelles colonnes](#)

Ajout d'informations sur la nouvelle option de configuration pour les robots d'exploration, MergeNewColumns. Pour plus d'informations, consultez [Configuration d'un crawler](#).

7 mai 2018

[Prise en charge du délai d'expiration des tâches](#)

Ajout d'informations sur la définition d'un seuil de délai d'expiration lorsqu'une tâche est exécutée. Pour plus d'informations, consultez [Ajout de tâches dans AWS Glue](#).

10 avril 2018

[Prise en charge du script ETL Scala et déclenchement des tâches en fonction des statuts d'exécution](#)

Informations supplémentaires sur l'utilisation de Scala comme langage de programmation ETL. De plus, l'API de déclenchement prend désormais en charge le déclenchement lorsque l'une des conditions est remplie (en plus de toutes les conditions). En outre, les tâches peuvent être déclenchées en fonction de l'« échec » ou de l'« arrêt » d'une tâche exécutée (en plus d'une exécution de tâche « réussie »).

12 janvier 2018

Mises à jour antérieures

Le tableau ci-après décrit les modifications importantes apportées dans chaque version du Manuel du développeur AWS Glue avant janvier 2018.

Modification	Description	Date
Prise en charge des sources de données XML et nouvelle option de configuration du crawler	Ajout d'informations sur la classification des sources de données XML et nouvelle option crawler pour les modifications de partition.	16 novembre 2017

Modification	Description	Date
Prise en charge de nouvelles transformations pour les moteurs de base de données Amazon RDS supplémentaires et améliorations des points de terminaison de développement	Ajout d'informations sur les transformations de filtrage et de mappage, prise en charge de Microsoft SQL Server sur Amazon RDS et Oracle sur Amazon RDS, et nouvelles fonctions pour les points de terminaison de développement.	29 septembre 2017
AWS Glue publication initiale	Il s'agit de la première version du Guide du développeur AWS Glue .	14 août 2017

AWS Glossaire

Pour la AWS terminologie la plus récente, consultez le [AWS glossaire](#) dans la Glossaire AWS référence.

Les traductions sont fournies par des outils de traduction automatique. En cas de conflit entre le contenu d'une traduction et celui de la version originale en anglais, la version anglaise prévaudra.